

**INSTITUTO SUPERIOR DE ENGENHARIA DE LISBOA**

**Área Departamental de Engenharia de Sistemas de Potência e Automação**



## **Previsão de Curto Prazo do Consumo de Energia Elétrica**

**PEDRO MIGUEL MARQUES ALVES**  
(Licenciado em Engenharia Electrotécnica)

Dissertação para a obtenção do grau de Mestre em  
Engenharia Electrotécnica – ramo de Energia

Orientadores:

Prof<sup>ª</sup>. Cristina Inês Camus

Assist. Eduardo Adelino Mateus Nunes Eusébio

Júri:

Presidente: Prof. Jorge Alberto Mendes de Sousa

Vogais:

Prof<sup>ª</sup>. Cristina Inês Camus

Assist. Eduardo Adelino Mateus Nunes Eusébio

Prof. Victor Manuel Fernandes Mendes

**Dezembro de 2013**





**INSTITUTO SUPERIOR DE ENGENHARIA DE LISBOA**  
**Área Departamental de Engenharia de Sistemas de Potência e Automação**



## **Previsão de Curto Prazo do Consumo de Energia Elétrica**

**PEDRO MIGUEL MARQUES ALVES**  
(Licenciado em Engenharia Eletrotécnica)

Dissertação para a obtenção do grau de Mestre em  
Engenharia Electrotécnica – ramo de Energia

Orientadores:

Prof<sup>ª</sup>. Cristina Inês Camus  
Assist. Eduardo Adelino Mateus Nunes Eusébio

Júri:

Presidente: Prof. Jorge Alberto Mendes de Sousa

Vogais:

Prof<sup>ª</sup>. Cristina Inês Camus  
Assist. Eduardo Adelino Mateus Nunes Eusébio  
Prof. Victor Manuel Fernandes Mendes

**Dezembro de 2013**



**Dissertação realizada sob orientação de:**

**Professora Cristina Inês Camus**

Professora Adjunta da Área Departamental  
de Engenharia de Sistemas de Potência e Automação

**Assistente Eduardo Adelino Eusébio**

Equiparado a Assistente 2º Triénio da Área Departamental  
de Engenharia de Sistemas de Potência e Automação



## Resumo

As metodologias de previsão de cargas elétricas têm sido alvo de um desenvolvimento considerável nos últimos anos, sendo hoje parte integrante dos atuais sistemas de planejamento e operação que se encontram ao dispor de empresas operadoras dos sistemas de energia elétrica.

Este desenvolvimento tem como principal causa a reestruturação do setor elétrico que conduziu à liberalização do mesmo em vários países. A liberalização, por sua vez trouxe consigo o aumento da complexidade organizativa e consequentemente a necessidade da previsão do consumo de energia elétrica.

Este trabalho incide sobre a problemática da previsão do consumo de energia elétrica em horizontes temporais de curto prazo. Tendo como ponto de partida os dados do passado relativos aos consumos verificados, disponibilizados pela REN, efetuar-se-á a análise do comportamento desta série temporal e posteriormente a previsão do consumo de energia elétrica.

Este estudo propõe e compara vários modelos de alisamento exponencial de *Holt-Winters* com dupla sazonalidade.

**Palavra-chave:** Previsão

Série temporal

Energia Elétrica

Alisamento exponencial





# Abstract

Load forecast methodologies had a significant development in recent years and play an important role for electric power systems corporations aim to render more efficient procedures like operation and planning of electric energy systems.

The reorganization of electric sector that led to the market liberalization in several countries was the main cause of this load forecast methodologies development. This development happened due to increased complexity of involved organizations and consequently the necessity to predict the energy consumption.

This work is about the issue of the load forecast in short periods. It attempts that knowing the energy consumes past data provided by REN and analyzing that time series, it will be able to have an electric load forecast.

This thesis proposes and compares several double seasonal Holt-Winters exponential smoothing methods.

**Keywords:** Forecasting

Time series

Electrical Energy

Exponential smoothing



## **Agradecimentos**

À professora Cristina Camus e ao professor Eduardo Eusébio, quero agradecer o acompanhamento e a supervisão indispensáveis à realização deste trabalho. De uma forma muito especial, agradecer toda a disponibilidade, dedicação, empenho e incentivo que tiveram comigo ao longo de todo este percurso. As suas sugestões, críticas e ensinamentos foram essenciais não só para o desenvolvimento deste trabalho como para o meu desenvolvimento pessoal.

O sincero agradecimento à minha família em especial ao meu Pai, Mãe e Irmão por todo o apoio e carinho e também pelo grande esforço que fizeram para que tudo isto fosse possível.

A todos os meus colegas do ISEL que me acompanharam e que sempre demonstraram espírito de união, em especial ao Ricardo Soares e ao Diogo Fernandes pela sua preciosa ajuda e apoio manifestado.

Finalmente, a todos os meus amigos por todo o apoio e amizade que sempre demonstraram ao longo de todo o meu percurso académico.



# Índice

1	Introdução .....	3
1.1	Enquadramento .....	3
1.2	Motivação .....	4
1.3	Objeto de Estudo .....	4
1.3.1	Objetivo/Hipóteses .....	5
1.4	Estrutura do Documento .....	5
1.5	Notação .....	6
2	Métodos de Previsão .....	9
2.1	Evolução dos Métodos de Previsão .....	9
2.2	Classificação dos Métodos de Previsão .....	10
2.2.1	Métodos Qualitativos .....	12
2.2.2	Métodos Quantitativos .....	14
3	Diagramas de Carga .....	23
3.1	Introdução .....	23
3.2	Análise de Diagramas de Carga .....	24
3.3	Tendência e Sazonalidade .....	35
4	Modelização .....	43
4.1	Introdução ao Modelo de Alisamento Exponencial de <i>Holt-Winters</i> .....	43
4.1.1	Modelo <i>Holt-Winters</i> Aditivo .....	43
4.1.2	Modelo <i>Holt-Winters</i> Multiplicativo .....	44
4.2	Modelos de Alisamento Exponencial de <i>Holt-Winters</i> com sazonalidade simples .....	45
4.3	Modelos de Alisamento Exponencial de <i>Holt-Winters</i> com dupla sazonalidade .....	47
4.3.1	Modelo de <i>Holt-Winters</i> Multiplicativo .....	47
4.3.2	Modelo de <i>Holt-Winters</i> com Tendência Suavizada .....	48
4.3.3	Modelo de <i>Holt-Winters</i> com Tendência Suavizada e Erros Estruturados .....	49
4.4	Valores Iniciais dos Parâmetros .....	49
4.5	Medidas de Erro de Previsão .....	51
4.6	Intervalo de Confiança .....	53

5	Casos de Estudo .....	57
5.1	Tratamento das Séries de Dados.....	57
5.2	Aplicação dos Modelos à Serie de Dados.....	57
5.2.1	Modelo de <i>Holt-Winters</i> Multiplicativo.....	59
5.2.2	Modelo de <i>Holt-Winters</i> com Tendência Suavizada.....	68
5.2.3	Modelo de <i>Holt-Winters</i> com Tendência Suavizada e Erros Estruturados .....	79
5.3	Comparação dos Erros de Previsão em Função do Tamanho da Série.....	89
5.3.1	Modelo de <i>Holt-Winters</i> Multiplicativo.....	90
5.3.2	Modelo de <i>Holt-Winters</i> com Tendência Suavizada.....	90
5.3.3	Modelo de <i>Holt-Winters</i> com Tendência Suavizada e Erros Estruturados .....	91
5.4	Comparação dos Modelos de Previsão .....	91
5.4.1	Série de 1 ano de dados com 8762 observações.....	92
5.4.2	Série de 1 ano de dados com 17524 observações.....	93
5.4.3	Série de 2 anos de dados com 17524 observações .....	94
5.5	Análise da Evolução Horária do Erro de Previsão .....	95
5.5.1	Modelo de <i>Holt-Winters</i> com Tendência Suavizada.....	95
5.5.2	Modelo de <i>Holt-Winters</i> com Tendência Suavizada e Erros Estruturados .....	96
6	Conclusões .....	101
6.1	Desenvolvimentos futuros .....	104
	Referências Bibliográficas.....	107

## Índice de Tabelas

Tabela 4.1- Métodos de alisamento exponencial. ....	46
Tabela 5.1 - Medidas de erro e de qualidade do ajuste do modelo. ....	59
Tabela 5.2 - Valores das constantes de amortecimento ao longo das sete semanas previstas. ....	59
Tabela 5.3 - Valores dos erros, para as sete semanas previstas. ....	60
Tabela 5.4 - Medidas de erro e de qualidade do ajuste do modelo. ....	63
Tabela 5.5 - Valores das constantes de amortecimento ao longo das sete semanas previstas. ....	63
Tabela 5.6 - Valores dos erros, para as sete semanas previstas. ....	64
Tabela 5.7 - Medidas de erro e de qualidade do ajuste do modelo. ....	66
Tabela 5.8 - Valores das constantes de amortecimento ao longo das sete semanas previstas. ....	66
Tabela 5.9 - Valores dos erros, para as sete semanas previstas. ....	67
Tabela 5.10 - Medidas de erro e de qualidade do ajuste do modelo. ....	69
Tabela 5.11 - Valores das constantes de amortecimento ao longo das sete semanas previstas. ....	69
Tabela 5.12 - Valores dos erros, para as sete semanas previstas. ....	70
Tabela 5.13 - Medidas de erro e de qualidade do ajuste do modelo. ....	73
Tabela 5.14 - Valores das constantes de amortecimento ao longo das sete semanas previstas. ....	73
Tabela 5.15 - Valores dos erros, para as sete semanas previstas. ....	74
Tabela 5.16 - Medidas de erro e de qualidade do ajuste do modelo. ....	76
Tabela 5.17 - Valores das constantes de amortecimento ao longo das sete semanas previstas. ....	76
Tabela 5.18 - Valores dos erros, para as sete semanas previstas. ....	77
Tabela 5.19 - Medidas de erro e de qualidade do ajuste do modelo. ....	79

Tabela 5.20 - Valores das constantes de amortecimento ao longo das sete semanas previstas. ....	80
Tabela 5.21 - Valores dos erros, para as sete semanas previstas. ....	80
Tabela 5.22 - Medidas de erro e de qualidade do ajuste do modelo. ....	83
Tabela 5.23 - Valores das constantes de amortecimento ao longo das sete semanas previstas. ....	83
Tabela 5.24 - Valores dos erros, para as sete semanas previstas. ....	84
Tabela 5.25 - Medidas de erro e de qualidade do ajuste do modelo. ....	86
Tabela 5.26 - Valores das constantes de amortecimento ao longo das sete semanas previstas. ....	86
Tabela 5.27 - Valores dos erros, para as sete semanas previstas. ....	87
Tabela 5.28 - Valores do MAPE, para os três modelos de previsão e média das semanas. ....	92
Tabela 5.29 - Valores do MAPE, para os três modelos de previsão e média das semanas. ....	93
Tabela 5.30 – Valores do MAPE, para os três modelos de previsão. ....	94
Tabela 5.31 – MAPE médio nas sete semanas para os três modelos e as três dimensões de séries .....	95



# Índice de Figuras

Figura 2.1 - Classificação dos métodos de previsão. ....	11
Figura 2.2 - Classificação de modelos de alisamento exponencial.....	18
Figura 3.1 - Diagrama de carga com discriminação dos parâmetros de caracterização .....	23
Figura 3.2 - Padrões de consumo típicos por classes de consumidores.....	24
Figura 3.3 - Diagrama de carga de um dia de Verão e de Inverno. ....	25
Figura 3.4 - Diagrama de carga anual. ....	26
Figura 3.5 - Diagrama de carga de uma semana. ....	26
Figura 3.6 - Diagrama de carga de uma semana com feriado.....	27
Figura 3.7 - Diagrama de carga com os diversos tipos de produção. ....	28
Figura 3.8 - Diagrama de carga da Rede Nacional de Transporte de Portugal.....	29
Figura 3.9 - Evolução do consumo de energia elétrica em Portugal. ....	29
Figura 3.10 - Evolução do consumo semanal em 2011 .....	30
Figura 3.11 - Pontas na rede em 2011.....	31
Figura 3.12 - Diagrama de carga ibérico. ....	31
Figura 3.13 - Diagrama de carga da Rede Elétrica de Espanha no dia 12 de Dezembro 2012 (Inverno) .....	32
Figura 3.14 - Diagrama de carga da rede elétrica Portuguesa no dia 12 de Dezembro 2012 (Inverno). ....	32
Figura 3.15 - Diagrama de carga da rede elétrica de transporte de França no dia 12 de Dezembro 2012 (Inverno).....	33
Figura 3.16 - Diagrama de carga da rede elétrica portuguesa no dia 4 de Julho de 2012 (Verão) .....	34
Figura 3.17 - Diagrama de carga da Rede Elétrica de Espanha no dia 4 de Julho 2012 (Verão) .....	34

Figura 3.18 - Diagrama de carga da rede elétrica de transporte de França no dia 4 de Julho 2012 (Verão) .....	35
Figura 3.19 - Características de uma serie temporal.....	36
Figura 3.20 - Diagrama de carga semanal. ....	37
Figura 3.21 - Diagrama de carga da RNT no mês de Janeiro de 2012. ....	38
Figura 3.22 - Exemplo de séries temporais com sazonalidade aditiva e multiplicativa. ....	38
Figura 3.23 - Variação anual do consumo de energia elétrica em Portugal. ....	39
Figura 5.1 - Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas.....	60
Figura 5.2 - Valores previstos relativos à melhor semana prevista (segunda semana). ....	61
Figura 5.3 - Intervalo de confiança de 95% para a melhor semana prevista. ....	61
Figura 5.4 - Valores previstos relativos à pior semana prevista (sexta semana). ..	62
Figura 5.5 - Intervalo de confiança de 95% para a pior semana prevista. ....	62
Figura 5.6 - Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas.....	63
Figura 5.7 - Valores previstos relativos à melhor semana (terceira semana). ....	64
Figura 5.8 - Intervalo de confiança de 95% para a melhor semana prevista. ....	64
Figura 5.9 - Valores previstos relativos à pior semana (sexta semana). ....	65
Figura 5.10 - Intervalo de confiança de 95% para a pior semana prevista. ....	65
Figura 5.11- Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas.....	66
Figura 5.12 - Valores previstos relativos à melhor semana prevista (segunda semana). ....	67
Figura 5.13 - Intervalo de confiança de 95% para a melhor semana prevista. ....	67
Figura 5.14 - Valores previstos relativos à pior semana prevista (sexta semana). 68	
Figura 5.15 - Intervalo de confiança de 95% para a pior semana prevista. ....	68

Figura 5.16 - Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas. ....	70
Figura 5.17 - Valores previstos relativos à melhor semana prevista (segunda semana). ....	71
Figura 5.18 - Intervalo de confiança de 95% para a melhor semana prevista. ....	71
Figura 5.19 - Valores previstos relativos à pior semana prevista (quarta semana). ....	72
Figura 5.20 - Intervalo de confiança de 95% para a pior semana prevista. ....	72
Figura 5.21 - Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas. ....	73
Figura 5.22 - Valores previstos relativos à melhor semana prevista (primeira semana). ....	74
Figura 5.23 - Intervalo de confiança de 95% para a pior semana prevista. ....	74
Figura 5.24 - Valores previstos relativos à pior semana prevista (sexta semana). ....	75
Figura 5.25 - Intervalo de confiança de 95% para a pior semana prevista. ....	75
Figura 5.26 - Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas. ....	76
Figura 5.27 - Valores previstos relativos à melhor semana prevista (segunda semana). ....	77
Figura 5.28 - Intervalo de confiança de 95% para a melhor semana prevista. ....	78
Figura 5.29 - Valores previstos relativos à pior semana prevista (quarta semana). ....	78
Figura 5.30 - Intervalo de confiança de 95% para a pior semana prevista. ....	79
Figura 5.31 - Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas. ....	80
Figura 5.32 - Valores previstos relativos à melhor semana prevista (segunda semana). ....	81
Figura 5.33 - Intervalo de confiança de 95% para a melhor semana prevista. ....	81
Figura 5.34 - Valores previstos relativos à pior semana prevista (quarta semana). ....	82
Figura 5.35 - Intervalo de confiança de 95% para a pior semana prevista. ....	82

Figura 5.36 - Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas. ....	83
Figura 5.37 - Valores previstos relativos à melhor semana prevista (primeira semana). ....	84
Figura 5.38 - Intervalo de confiança de 95% para a melhor semana prevista. ....	84
Figura 5.39 - Valores previstos relativos à pior semana prevista (sexta semana). ....	85
Figura 5.40 - Intervalo de confiança de 95% para a pior semana prevista. ....	85
Figura 5.41 - Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas. ....	86
Figura 5.42 - Valores previstos relativos à melhor semana prevista (segunda semana). ....	87
Figura 5.43 - Intervalo de confiança de 95% para a melhor semana prevista. ....	88
Figura 5.44 - Valores previstos relativos à pior semana prevista (quarta semana). ....	88
Figura 5.45 - Intervalo de confiança de 95% para a pior semana prevista. ....	89
Figura 5.46 - Evolução do MAPE ao longo das sete semanas com diferentes tamanhos de série. ....	90
Figura 5.47 - Evolução do MAPE ao longo das sete semanas com diferentes tamanhos de série. ....	90
Figura 5.48 - Evolução do MAPE ao longo das sete semanas com diferentes tamanhos de série. ....	91
Figura 5.49 - Evolução do MAPE ao longo das sete semanas para os três modelos de previsão. ....	92
Figura 5.50 - Evolução do MAPE ao longo das sete semanas para os três modelos de previsão. ....	93
Figura 5.51 - Evolução do MAPE ao longo das sete semanas para os três modelos de previsão e média das semanas. ....	94
Figura 5.52 - Evolução horária do QME para a melhor semana prevista. ....	96
Figura 5.53 - Evolução horária do QME para três semanas previstas. ....	96

Figura 5.54 - Evolução horária do QME para a melhor semana prevista.....	97
Figura 5.55 - Evolução horária do QME para três semanas previstas. ....	97



## Lista de Acrónimos

ARIMA	<i>Autoregressive integrated moving average</i>
EMA	Erro médio absoluto
MAPE	Erro percentual médio absoluto
PRE	Produção em regime especial
PRO	Produção em regime ordinário
QME	Erro médio quadrático
REE	Rede elétrica de Espanha
REN	Rede elétrica nacional
RNT	Rede nacional de transporte
RTE	Rede de transporte de Eletricidade Francesa
SEN	Sistema elétrico nacional





## Lista de Símbolos

$D_t$	Sazonalidade diária
$I_t$	Sazonalidade diária
$k$	Intervalo da previsão
$R^2$	Estatística de teste
$S_1$	Fator de sazonalidade diária
$S_2$	Fator de sazonalidade semanal
$S_t$	Nível
$T_t$	Tendência
$U$	Estatística <i>U Theil</i>
$W_t$	Sazonalidade semanal
$X_t$	Valor real da série temporal
$\hat{X}_t$	Valor previsto
$\alpha$	Parâmetro de alisamento do modelo de <i>Holt-Winters</i>
$\delta$	Parâmetro de alisamento do modelo de <i>Holt-Winters</i>
$\varepsilon_t$	Erro
$\lambda$	Parâmetro de alisamento do modelo de <i>Holt-Winters</i>
$\sigma$	Variância
$\gamma$	Parâmetro de alisamento do modelo de <i>Holt-Winters</i>
$\omega$	Parâmetro de alisamento do modelo de <i>Holt-Winters</i>
$\phi$	Parâmetro de alisamento do modelo de <i>Holt-Winters</i>



---

# Capítulo 1

---

## Introdução

*Neste capítulo é feita uma introdução à problemática da previsão do consumo de energia elétrica. Apresenta-se o enquadramento da dissertação, algumas ideias fundamentais que motivaram a abordagem a esta temática e o objeto de estudo. Descreve-se ainda a forma como o texto está organizado, assim como a notação utilizada neste trabalho.*



# 1 Introdução

## 1.1 Enquadramento

A energia elétrica tornou-se nas últimas décadas um bem cada vez mais importante para a sociedade, com o desenvolvimento tecnológico e a crescente industrialização.

Contrariamente ao que acontece com outros produtos, a energia elétrica tem de ser consumida imediatamente após a sua produção, uma vez que esta não pode ser armazenada em grande escala, devido a esta particularidade é extremamente importante para produtores e distribuidores prever com a melhor exatidão possível o consumo de energia elétrica.

Devido à situação económica atual e à grande concorrência entre organizações existentes nos dias de hoje, torna-se fundamental desenvolver métodos que permitam otimizar os recursos existentes. Consequentemente, nasce a necessidade de desenvolver métodos de previsão aplicados ao comportamento do consumo num futuro próximo. Com o desenvolvimento destes métodos é possível obter uma elevada qualidade na previsão o que permitirá uma redução de custos, através da otimização da energia produzida e também de uma melhor distribuição do consumo pelas fontes produtoras existentes no sistema elétrico nacional.

Este trabalho enquadra-se no âmbito da previsão do consumo de energia elétrica em Portugal recorrendo a métodos de alisamento exponencial de *Holt-Winters*, este método é utilizado normalmente para prever variáveis cujas suas séries temporais apresentem sazonalidades, isto é, que o seu comportamento padrão tende a repetir-se num determinado espaço de tempo. Pela sua precisão e robustez o método é utilizado em várias áreas em especial no consumo de energia, gerando assim previsões com um único padrão de sazonalidade, no entanto mais recentemente expandiu-se o uso do método de *Holt-Winters* tradicional para um modelo com dois padrões de sazonalidade [1].

## 1.2 Motivação

A previsão assume atualmente grande importância em várias áreas da sociedade, nomeadamente no planeamento operacional de sistemas de energia elétrica, podendo representar uma redução significativa dos custos de empresas produtoras e distribuidoras de energia.

O problema da previsão do consumo de energia visa conhecer, com alguma antecedência, os padrões de consumo de forma a satisfazer as necessidades energéticas, uma vez que, para toda a carga consumida terá de ser produzida a mesma quantidade de energia. Como a capacidade de armazenamento de energia é um dos grandes problemas de engenharia na atual idade, torna-se vital prever o comportamento de uma carga para posteriormente efetuar o planeamento da produção. Este tipo de problemas tem uma complexidade subjacente, que está relacionada, não só com os diferentes tipos de consumidores existentes, mas também com o aparecimento de novas interligações com fontes de energia renováveis.

A previsão apresenta também um papel muito importante ao nível económico, uma vez que quanto mais precisa for, ou seja, quanto menor for o erro de previsão, menor será a necessidade de reserva girante dos geradores e dessa forma melhorar a eficiência do planeamento de produção de energia.

Por estas razões, a problemática da previsão de consumos de energia é um dos grandes desafios para as empresas produtoras, distribuidoras e de comercialização de energia de forma a racionalizar os recursos existentes.

## 1.3 Objeto de Estudo

Inicialmente será definida a formulação do problema, que dará origem aos objetivos propostos para esta dissertação, a minha pretensão é realizar a previsão do consumo nacional de energia elétrica, através da implementação de metodologias de alisamento exponencial, designadas por métodos de *Holt-Winters*. Desta forma, o objeto da dissertação consistirá nas seguintes questões:

- Realizar uma discussão sobre a conjugação entre tendência e sazonalidade, nas suas variantes (aditiva, multiplicativa e multiplicativa suavizada).

- Qual ou quais das anteriores variantes que melhor se aplicam à série de consumos de energia elétrica portuguesa.
- Determinar o tamanho da série de dados que conduz a melhores previsões bem como diferentes tentativas de obtenção dos melhores parâmetros dos modelos.

### 1.3.1 Objetivo/Hipóteses

O principal objetivo da dissertação proposta é dar resposta aos problemas apresentados anteriormente, e perceber a influência da conjugação entre tendência e sazonalidade, mais especificamente estas conjugações serão implementadas em *Matlab/Excel*, no qual serão visualizados os perfis de consumo previstos (diário e semanal) bem como os respetivos erros de previsão associados.

## 1.4 Estrutura do Documento

Esta dissertação está organizada em 6 capítulos distintos, partindo de uma abordagem geral para o aprofundar do tema em estudo de capítulo para capítulo.

No capítulo 1 é feito um enquadramento à temática da previsão, é ainda referida a motivação o objeto de estudo e o objetivo deste trabalho. De maneira a facilitar a compreensão e leitura da dissertação é apresentada a notação usada neste documento.

No capítulo 2 é realizada uma abordagem sobre a evolução dos métodos de previsão ao longo da história tal como a classificação dos mesmos. É também apresentada a descrição de alguns métodos, com especial atenção para os de alisamento exponencial abordados nesta dissertação.

No capítulo 3 são expostas diversas características dos diagramas de carga e feita uma abordagem sobre os parâmetros e as características dos diagramas de forma a facilitar a compreensão e a posterior análise dos mesmos.

No capítulo 4 é feita uma abordagem à metodologia utilizada para efetuar a previsão do consumo. Apresentam-se também as principais características que compõem a modelização, aprofundando os modelos que se adaptam aos casos de estudo.

No capítulo 5 são apresentados os vários casos de estudo, tendo sempre como ponto de partida a base teórica apresentada nos capítulos anteriores. São também apresentados os resultados obtidos pelos vários modelos e feitas algumas comparações entre os mesmos,

de forma a que seja possível aferir qual o mais adequado para efetuar a previsão do consumo.

No capítulo 6 são apresentadas as principais conclusões acerca do trabalho realizado nos capítulos anteriores e apresentada a proposta de desenvolvimento futuro.

## **1.5 Notação**

A identificação de referências bibliográficas será representada entre parênteses retos [ ], da mesma forma a numeração de expressões é apresentada entre parênteses curvos ( ) e terá dois algarismos, o primeiro referente ao número do capítulo em que este se encontra e o segundo representa o número da equação em cada capítulo. Em relação às figuras e tabelas estas são apresentadas igualmente com dois algarismos com referência ao capítulo em que são apresentadas e numeradas de forma sequencial. Posteriormente ao índice de tabelas e figuras são apresentadas as listas de acrónimos e símbolos.

As referências bibliográficas estão indicadas de acordo com IEEE 2006 revisão 2010.



---

## Capítulo 2

---

# Métodos de Previsão

*Neste capítulo é feita uma abordagem sobre a evolução dos métodos de previsão ao longo da história tal como a classificação dos mesmos. É também apresentada a descrição de alguns métodos, com especial atenção para os de alisamento exponencial abordados nesta dissertação.*



## 2 Métodos de Previsão

### 2.1 Evolução dos Métodos de Previsão

Durante muitos anos a previsão foi encarada como uma atividade com pouco rigor científico, uma vez que estas eram realizadas por profetas, astrólogos entre outros, que se baseavam em visões, sonhos ou na posição das estrelas para prever o futuro.

Na sociedade atual, poucos acreditam que a melhor forma de prever o futuro resida na posição das estrelas ou em visões, a superstição deu lugar à racionalidade e o estudo desta temática tornou-se científico. No século XIX, economistas e matemáticos procuraram realizar previsões analisando padrões históricos e sua posterior extrapolação para o futuro [2].

Até à década de cinquenta, grande parte das metodologias utilizadas baseava-se em métodos qualitativos, apesar de já existir uma grande variedade de métodos quantitativos, estes tinham no entanto algumas restrições, nomeadamente o facto de não existirem equipamentos com capacidade para realizar um volume considerável de processamento, o que limitava o potencial desta metodologia [2].

A partir da década de sessenta, devido ao uso generalizado da informática, passaram a ser mais utilizados os métodos quantitativos, em especial as metodologias univariáveis. Na década de setenta, para além da evolução informática, e da crescente capacidade de processamento de informação, houve também um desenvolvimento ao nível das técnicas quantitativas existentes, em especial de modelos multivariáveis [2].

No final da década de setenta, o aumento da turbulência ambiental e recessões, mostrou que a melhor solução seria a integração de métodos de previsão e um melhor uso das metodologias existentes [2]

Atualmente a necessidade de otimizar a integração das diferentes metodologias levou ao desenvolvimento de ferramentas estatísticas de *software*, obtendo-se o menor erro possível, dessa forma é possível reduzir um fator bastante importante na tomada de decisões, a incerteza. Esta incerteza impede o conhecimento exato do comportamento futuro, o que leva à necessidade de produzir previsões que apresentem um elevado nível de precisão.

A previsão de valores futuros pode ser realizada recorrendo a diferentes metodologias, dependendo do tipo de utilização, extensão (longo, médio e curto prazo) e também em função da existência de dados históricos.

## 2.2 Classificação dos Métodos de Previsão

Os métodos de previsão podem ser classificados com base no horizonte de tempo de previsão podendo ser de curto, médio e longo prazo [3].

- **Previsões de curto prazo**

O período associado a este tipo de previsão varia entre um dia a um mês. Estes métodos são normalmente utilizados para a otimização da geração de energia e são essenciais para a operação de sistemas de produção de forma a garantir a fiabilidade do fornecimento de energia elétrica.

- **Previsões de médio prazo**

O horizonte temporal associado a este tipo de previsão está situado entre um mês e um ano. Este tipo de previsão é importante na calendarização de procedimentos de manutenção, tal como na tomada de decisões relativas à necessidade de matérias-primas para a produção de energia.

- **Previsões de longo prazo**

São previsões que são feitas para prazos superiores a um ano, e são importantes para o planeamento estratégico das empresas, são usadas por exemplo para planear a expansão do sistema de transporte e distribuição de energia elétrica.

Este trabalho vai focar-se essencialmente nas previsões a curto prazo, este tipo de previsões pode ser executada de duas formas, *online* e *offline*. Esta caracterização está ligada à sua área de aplicação, a previsão *offline* do consumo de energia é normalmente implementada pelas entidades responsáveis pela produção de energia no planeamento dos tempos de arranque dos geradores, e representa grande importância para as mesmas, uma vez que se a previsão apresentar um elevado erro, pode levar a um incorreto planeamento, o que terá como consequência o aumento dos custos operacionais [4].

Por outro lado, a operação *online* do sistema de energia, está relacionada com o despacho económico que tem como objetivo calcular o perfil ótimo de produção de energia considerando disponíveis várias centrais e desta forma satisfazer o consumo. Este cálculo é baseado nos valores de carga previstos com o avanço de algumas horas, e está dependente da precisão da previsão *online* [4].

Os métodos de previsão podem ainda ser divididos em duas grandes categorias: métodos qualitativos e quantitativos.

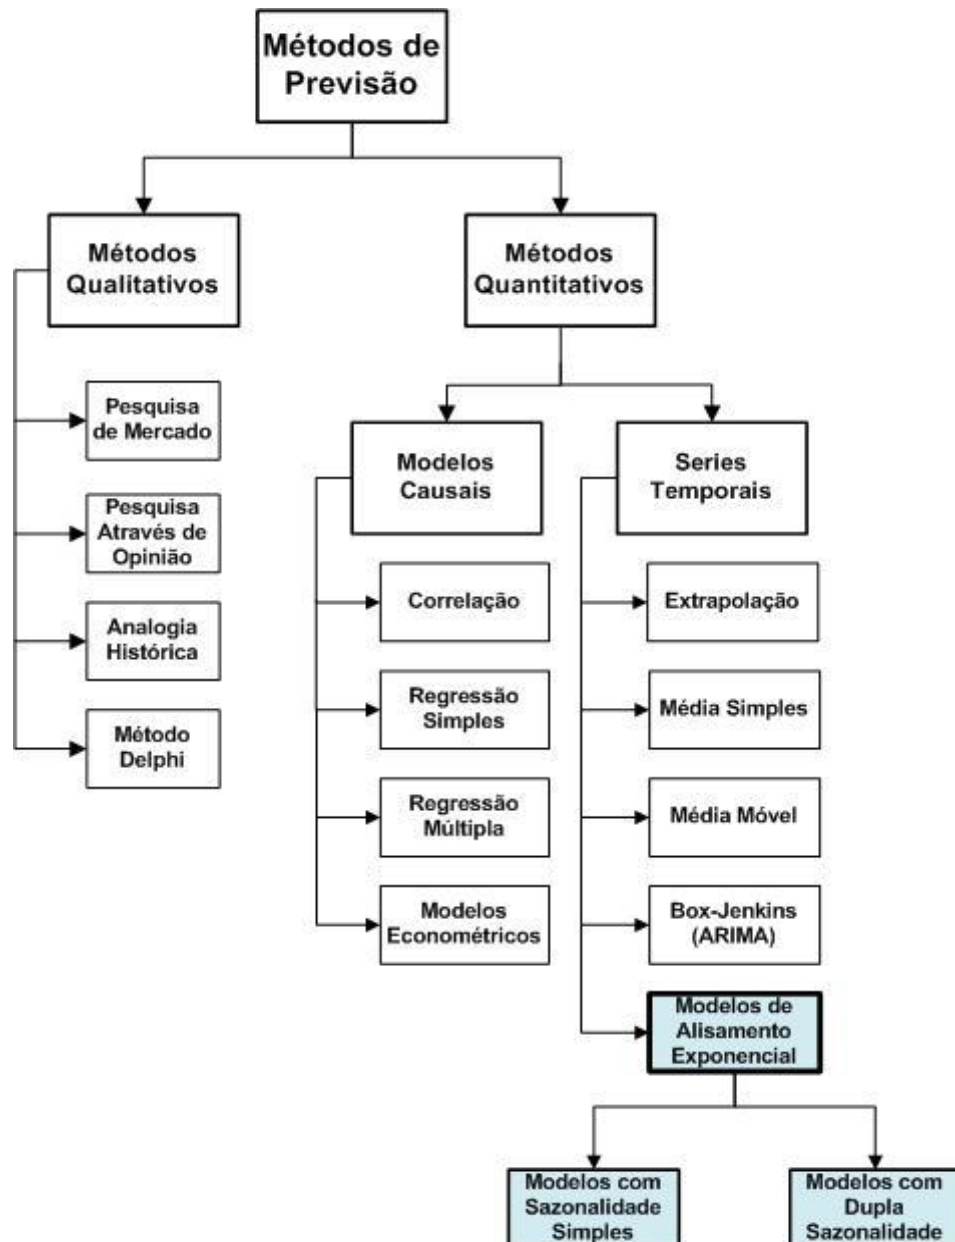


Figura 2.1 - Classificação dos métodos de previsão.

### **2.2.1 Métodos Qualitativos**

São aqueles que recorrem a pesquisas ou técnicas comparativas com o objetivo de produzir estimativas relativas ao futuro. Neste tipo de modelos é possível que não existam dados históricos ou que, caso existam, tenham escassa relevância para a previsão. Pelo fato de a natureza do modelo não ser científica é difícil a validação da sua exatidão, estes métodos são utilizados em estudos de opinião, trabalhos de previsão de dados teóricos onde os valores numéricos não têm grande influência [5].

Por exemplo, considerando a situação em que um novo produto vai ser introduzido no mercado, neste caso não existe um historial de vendas para este produto. Para prever as vendas deste novo produto, uma empresa deve basear-se na opinião de membros do departamento de vendas, uma vez que possuem experiência neste tipo de situações. Outra situação em que não existem dados históricos disponíveis e dessa forma não terão influência na previsão será por exemplo a descoberta de uma nova tecnologia e a sua aplicação.

Os métodos qualitativos são utilizados também para prever mudanças nos padrões históricos, a utilização de dados históricos para prever o futuro é baseada no facto de que esses dados se repetirão no futuro, logo as alterações nestes padrões históricos não podem ser previstas com base nos mesmos padrões [6].

Em seguida será feita uma breve descrição sobre alguns métodos qualitativos de previsão normalmente utilizados tais como:

- Pesquisa de mercado;
- Pesquisa através de opinião;
- Analogia histórica;
- Método de Delphi.

#### **Pesquisa de Mercado**

Este método representa a expectativa que existe das necessidades de compra dos consumidores. Tem em conta as previsões de negócios estimados por empresas de pesquisa. Uma das grandes dificuldades que se encontra neste tipo de pesquisa é a obtenção de informações conclusivas acerca das intenções de compra, uma vez que a

pesquisa é feita a uma amostra reduzida de pessoas entrevistadas, sendo que estas devem ser criteriosamente escolhidas de forma a representar o consumidor alvo [2].

### **Pesquisa através de Opinião**

Este método pode ser explicado através do exemplo seguinte, um vendedor com base na sua expectativa de vendas, é convidado para fazer uma estimativa de vendas de uma empresa para o próximo ano. O somatório das previsões de vários vendedores fornece a previsão global das vendas, sendo que os vendedores são os elementos da empresa que melhor conhecimento tem do mercado [2].

A principal vantagens deste método é o aproveitamento do *know how* dos vendedores, fazendo com que tenham mais confiança nos critérios estabelecidos das quotas atribuídas aos mesmo, comprometendo e responsabilizando os vendedores no cumprimento das previsões. Por outro lado, esta situação apresenta alguns inconvenientes tais como, hipóteses abaixo das possibilidades de vendas, de forma a reduzir o valor da quota de vendas fixada através da previsão de vendas [2].

### **Analogia Histórica**

Este método é constituído por uma análise comparativa dos vários estágios do ciclo de vida de um produto similar ao que se pretende lançar no mercado. Normalmente são considerados três estágios para a venda de um produto: crescimento, maturidade e declínio. No estágio de crescimento as vendas começam por crescer até ser atingido o estágio de maturidade, onde existe uma estabilização das vendas e finalmente no estágio final, existirá um declínio nas vendas. Desta forma é possível comparar os ciclos de vida de produtos similares obtendo assim uma previsão de vendas para o novo produto [6].

### **Método de Delphi**

Neste método, desenvolvido pela *RAND Corporation*, um painel de especialistas é consultado para produzir previsões relacionadas com uma questão específica, como por exemplo ocorrer um novo desenvolvimento tecnológico. Este método parte do princípio que o painel de especialistas não só apresenta experiência comprovada, mas também que a combinação do conhecimento dos vários membros vai fazer com que a previsão seja, pelo

menos, tão precisa quanto a que resultaria se fosse produzida apenas por cada um dos membros.

Este método procura obter consenso do grupo de forma sistemática através de avaliações individuais, de forma a manter os vários membros do painel separados fisicamente, tentando evitar assim influências psicológicas ou que a discussão seja dominada por um indivíduo ou por um grupo de pessoas. Este método apresenta uma elevada ocorrência de ambiguidade nos questionários o que pode levar a que não exista convergência [6].

## **2.2.2 Métodos Quantitativos**

Estes métodos têm como base a análise de dados históricos como forma de prever os futuros valores de uma variável de interesse e pressupõem que os padrões de comportamento do passado se irão manter no futuro. Estes métodos subdividem-se em dois tipos: modelos causais e séries temporais.

### **2.2.2.1 Modelos Causais**

Este modelo considera a identificação de outras variáveis que estão relacionadas com a variável de previsão e pressupõem uma relação causa efeito entre os *inputs* e *outputs* do sistema em estudo.

O objetivo deste modelo de previsão é encontrar essas relações, através da análise dos resultados dos *outputs*. Por exemplo, as vendas de um determinado produto podem estar relacionadas com o preço do produto, gastos com campanhas publicitárias para promover o produto entre outras variáveis, ou seja a variável de previsão está dependente de outras variáveis independentes. Neste caso o objetivo do modelo seria encontrar a relação entre as vendas e as suas variáveis independentes [6].

Os modelos causais podem dividir-se em: correlação e regressão simples, regressão múltipla e modelos econométricos.



## **Correlação e regressão simples**

A análise de regressão é bastante utilizada para executar previsões, esta análise pode envolver desde fatores simples (regressão simples) para a determinação de um dado concreto, até múltiplos fatores (regressão múltipla). Os diversos fatores apresentam uma relação de correlação que pode ou não ser linear.

Na análise da regressão simples assume-se que uma variável dependente se relaciona linearmente com uma variável independente. A análise de regressão linear tem como objetivo encontrar a reta que melhor se ajusta a um conjunto de observações. A precisão desta análise é medida através do coeficiente de determinação, que representa a relação entre a soma dos quadrados dos desvios obtidos pela reta de regressão, a média das observações e a soma dos quadrados dos desvios das observações.

A qualidade de uma regressão é normalmente medida através do coeficiente de correlação, que representa a raiz quadrada do coeficiente de determinação. O coeficiente de correlação pode variar de -1 a 1, onde 0 representa a ausência de correlação. Para que o modelo de regressão seja credível, é necessário que o coeficiente de correlação seja menor que -0,7 ou maior que 0,7 [6].

A regressão múltipla adota os mesmos princípios que a regressão simples, a principal diferença está relacionada com o fato de associar mais do que uma variável independente à mesma variável dependente. [2]

## **Modelos econométricos**

Nos modelos de regressão simples e múltipla observa-se que, os mesmos apresentam apenas uma equação, isto significa que todos os elementos dessa mesma equação são tratados da mesma maneira.

Tendo como exemplo a regressão múltipla, existem vários acontecimentos que interferem com uma determinada variável, sendo que se trata esta variável de forma endógena, apenas são considerados os resultados da mesma, ignorando-se assim a interferência de outros fatores.

Num modelo econométrico são consideradas as variáveis endógenas e as variáveis exógenas, ou seja, são considerados fatores exteriores à variável a prever, isto leva a que este tipo de modelos apresente resultados com maior precisão, relativamente aos modelos

de regressão. Estes modelos são normalmente utilizados para ajudar governos e grandes empresas a tomar as suas decisões a longo prazo, e apresentam alguma complexidade ao nível do processamento [2].

#### **2.2.2.2 Series Temporais**

Este método baseia-se em dados históricos para prever futuros valores de uma série temporal. Ao contrário do que acontece nos modelos causais, a previsão através de séries temporais, devido à dificuldade de compreensão e organização dos dados, trata o sistema como uma caixa negra. Este método torna-se muito útil quando se espera que as condições se mantenham as mesmas no futuro apresentado algumas limitações no caso destas condições não se verificarem. Como exemplo, este modelo pode ser usado para prever as vendas expectáveis de uma determinada empresa que irá continuar a utilizar a mesma estratégia de *marketing*, por outro lado, este modelo não terá a mesma utilidade se o objetivo for prever a variação das vendas provocada por um aumento do preço [6].

Os métodos de séries temporais geralmente utilizados podem ser: extrapolação, média simples, média móvel, Box-Jenkins (ARIMA) e modelos de *Holt-Winters* (alisamento exponencial).

#### **Extrapolação**

Os métodos estatísticos de extrapolação são construídos com base na ideia de que os padrões históricos existentes se repetirão no futuro. Esta consideração possui maior probabilidade de suceder para horizontes temporais de curto prazo. Desta forma, os métodos baseados nesta técnica apresentam maior precisão para previsões de curto prazo ou extremamente estáveis ao longo do tempo [7].

#### **Média simples**

O método da média simples consiste em fazer a previsão a partir da média aritmética dos dados passados. Este método apresenta uma grande desvantagem, uma vez que é influenciado por dados que apresentam grandes discrepâncias, ou seja, a previsão será influenciada por dados aleatórios de alguma anormalidade presente na série temporal.

Outro dos inconvenientes é que este método considera o mesmo peso para todos os dados históricos [2].

### **Média móvel**

O método da média móvel é muito utilizado por empresas e organizações, por ser extremamente simples e necessitar de poucos dados históricos. É apropriado para previsões de curto prazo onde as componentes de tendência e sazonalidade sejam desprezáveis ou mesmo inexistentes [7].

A técnica utilizada neste método é uma simples previsão exponencial onde são considerados os  $k$  dados históricos mais recentes e com estes é realizada uma média aritmética para prever o valor seguinte. O número de observações em cada cálculo da média mantém-se constante e é ajustado de forma a atenuar distorções, e dessa forma suavizar as curvas que apresentam tendência e sazonalidade [7].

As desvantagens deste método estão relacionadas com o fato de produzir resultados de previsão que dependem de  $k$ , logo se  $k$  for muito baixo, a média poderá estar a adicionar valores aleatórios com grande discrepância. Por outro lado, se o valor de  $k$  for demasiado elevado, a média não será muito sensível às variações, ou seja, as variações reais da série temporal não seriam consideradas [2].

### ***Box-Jenkins* (ARIMA)**

As séries temporais são ajustadas com modelos matemáticos que são muito úteis uma vez que apresentam, normalmente, erros muito reduzidos. Os dados históricos, ordenados por ordem cronológica, apresentam uma espécie de dependência entre os números de um período para o outro, a esta dependência dá-se o nome de autocorrelação [2].

No modelo de *Box-Jenkins* são feitas várias análises à série temporal, entre as quais, análise da autocorrelação e autocorrelações parciais, em seguida, é calculada uma estimação dos parâmetros, minimizando dessa forma o erro médio quadrático. Esta é uma das grandes vantagens deste método, uma vez que através da análise da autocorrelação é possível efetuar um diagnóstico dos resíduos de maneira a que os parâmetros estimados apresentem o erro médio quadrático mínimo [2].

Este modelo, apesar de ser uma das ferramentas estatísticas com maior precisão é também bastante complexo o que pode levar a ser necessário despende grande quantidade de tempo para a construção do modelo [2].

### **Modelos de Alisamento Exponencial**

Esta dissertação visa a utilização dos modelos de alisamento exponencial ou modelos de *Holt-Winters*, devido à sua precisão e robustez, estes métodos possuem uso difundido em várias áreas, entre as quais a área da previsão do consumo de energia elétrica, sendo que, estes modelos são reconhecidos como uma das ferramentas mais utilizadas na previsão a curto prazo. Esta metodologia tem como vantagem a possibilidade de produzir previsões de séries temporais que apresentem sazonalidade, como é o caso típico das séries de consumo de energia [1].

Serão abordados dois tipos de modelos de *Holt-Winters*, os modelos de alisamento exponencial que geram previsões com um único padrão sazonal/ciclo e também os modelos de alisamento exponencial com dupla sazonalidade, ou seja com dois padrões sazonais/ciclos (Figura 2.2).




Figura 2.2 - Classificação de modelos de alisamento exponencial.

#### **1. Modelos de Alisamento Exponencial com Sazonalidade Simples**

Este tipo de método estatístico parte de uma equação de médias móveis, com o objetivo de ajustar as variações aleatórias dos dados de uma determinada série temporal. Esse processo de alisamento utiliza pesos distintos para cada valor observado na série temporal, para que os valores mais recentes recebam pesos maiores. Assim, os pesos formam um conjunto que decai a partir dos valores mais recentes.

Os modelos de alisamento exponencial utilizam apenas observações da própria série de dados, ou seja, não dependem de nenhuma variável externa para realizar previsões e são

utilizados quando as séries temporais apresentam tendência e sazonalidade. A sazonalidade é definida como a propensão que a série de dados possui para se repetir num determinado período de tempo.

A sazonalidade pode ser caracterizada de duas formas, podendo ser, aditiva ou multiplicativa. Através da análise da série temporal é possível distinguir as características destes dois tipos de componentes sazonais, no caso da aditiva a série apresenta flutuações sazonais estáveis independentemente do nível global da série, já na situação da sazonalidade multiplicativa o tamanho das flutuações sazonais variam dependendo do nível da série [8].

Os métodos de alisamento exponencial incluem nove diferentes métodos, cada um é classificado como sendo adequado para séries com nível constante, tendência aditiva, multiplicativa ou aditiva amortecida, sem sazonalidade, com sazonalidade aditiva ou multiplicativa [9].

Estes métodos são amplamente utilizados em várias áreas, no estudo realizado em [10] os autores utilizam o método de alisamento exponencial para prever séries de intervalos de valores, que podem ser utilizados em vários campos, tais como, o preço das ações de uma empresa, que pode ser apresentado pelo menor e pelo maior preço diário. Na área da engenharia, os intervalos de valores podem ser utilizados para representar a variação da corrente elétrica num determinado dia.

Em [11], é adotado o modelo de *Holt-Winters* para prever a procura na indústria retalhista, com os objetivos de reduzir o excesso de *stock*, conhecer o tipo de procura por parte do consumidor e dessa forma aumentar a margem de lucro.

Relativamente à previsão do consumo de energia elétrica em [12], são utilizados os dados do consumo de eletricidade Britânico para construir um modelo de alisamento exponencial que prevê o consumo nos 10 a 30 minutos seguintes aos dados analisados. Este tipo de previsão, num curtíssimo prazo tem especial relevância no mercado de energia, onde as reservas de geração são mantidas a um nível mínimo, estipulado pelo operador de sistema.

## **2. Modelos de Alisamento Exponencial com Dupla Sazonalidade**

Os modelos padrão de *Holt-Winters* são bastante utilizados na previsão de séries temporais que apresentam sazonalidades, mas estes modelos normalmente consideram apenas um padrão sazonal. Para séries que apresentem dois padrões sazonais/ciclo, os modelos com dupla sazonalidade podem apresentar melhores resultados ao nível da precisão da previsão.

Em [1], é utilizado o modelo de *Holt-Winters* de alisamento exponencial com dupla sazonalidade para fazer uma previsão do consumo de energia elétrica em Inglaterra e País de Gales. Este tipo de previsão *online* do consumo de energia elétrica que é essencial para o planeamento e controlo dos sistemas de potência, e é feita para o horizonte temporal de um minuto até um dia.

A utilização de modelos com dupla sazonalidade na previsão do consumo de energia elétrica foi também estudada em [13], para a região sudeste do Brasil. Esta previsão foi feita para cada quinze minutos, sendo o horizonte de previsão também de quinze minutos. Foram considerados dois ciclos sazonais, sendo eles o diário e o semanal.

Este método foi também utilizado para estudar o efeito da geração eólica na previsão do preço da eletricidade em Espanha [14]. Uma vez que existem evidências de que a precisão da previsão do preço da eletricidade pode ser melhorada se for considerada a previsão da geração eólica.

---

## Capítulo 3

---

# Diagramas de Carga

*Neste capítulo pretende-se apresentar diversas considerações sobre a caracterização de diagramas de carga, analisando as suas características e expondo alguns exemplos de diagramas típicos. Inicialmente será feita uma abordagem sobre os parâmetros e as características dos diagramas de forma a facilitar a compreensão e a posterior análise dos mesmos.*





## 3 Diagramas de Carga

### 3.1 Introdução

Os diagramas de carga são normalmente utilizados na engenharia para a análise de cargas eléctrica, estes são construídos através do valor médio de carga num determinado período de tempo, este período é normalmente medido numa hora como mostra a Figura 3.1, mas também pode ser medido em intervalos de 15 minutos, 30 minutos, diariamente ou mesmo mensalmente. O valor médio de potência consumida neste intervalo de tempo é dado pela potência acumulada dividida pela dimensão do mesmo e pode ser representado graficamente para qualquer ponto da rede (aparelhos de uso final, consumidor, postos de transformação, subestações e unidades de produção).




Figura 3.1 - Diagrama de carga com discriminação dos parâmetros de caracterização.

O diagrama de carga representa o padrão de carga num determinado intervalo de tempo, para um melhor entendimento deste tipo de diagramas é importante reiterar alguns conceitos largamente divulgados. Observando a Figura 3.1, a ordenada máxima P, é normalmente designada por ponta do diagrama de carga no intervalo em estudo, embora a designação do termo “ponta”, seja usualmente aplicada a todos os máximos locais do diagrama.

Desta forma, pode-se observar duas pontas relevantes, P representa a ponta da tarde e P' a ponta da manhã (Figura 3.1). Por outro lado, podemos designar as depressões encontradas neste tipo de diagramas por “vazio”. Em A está representado o chamado vazio da noite e em B o vazio da tarde [15] [16].

### 3.2 Análise de Diagramas de Carga

Apesar de o consumo de energia ser diferente em cada consumidor, existe no entanto alguns padrões de consumo. Dessa forma, os consumidores podem ser caracterizados de três formas, consumidores residenciais, comerciais e industriais. O padrão de carga típico dos respectivos consumidores encontra-se representado na Figura 3.2. Quando se fala do consumo de energia global de um determinado país estas três classes encontram-se agregadas.




Figura 3.2 - Padrões de consumo típicos por classes de consumidores [16].

O padrão de carga sofre também algumas alterações significativas consoante a época do ano, consequência natural dos hábitos e certas rotinas diárias serem também distintas. Por exemplo, o funcionamento dos sistemas de ar-condicionado é mais regular no verão, em especial nas horas de maior calor. Já no Inverno, a ponta da noite é mais prolongada devido ao normal decréscimo da temperatura e consequentemente existir a necessidade de

recorrer a sistemas de aquecimento. Na Figura 3.3 observa-se a diferença entre o consumo de energia elétrica num dia de verão relativamente a um dia de inverno em Portugal.




Figura 3.3 - Diagrama de carga de um dia de Verão e de Inverno.

A forma e os valores médios da potência apresentados nos diagramas de carga são fortemente influenciados pelas estações climáticas. Ao visualizarmos o padrão de carga anual em Portugal, é notória uma redução da potência sempre que ocorre uma transição das estações frias para as quentes, como pode ser visto na Figura 3.4. Apesar destas transições, é possível verificar um comportamento cíclico semanal, que está relacionado com o fato de existirem comportamentos semelhantes em dias homólogos.




Figura 3.4 - Diagrama de carga anual.

Este tipo de diagramas apresentam comportamentos cíclicos, que podem ser classificados como sendo: anuais, semanais e diários. A repetição diária está relacionada com os hábitos e certas rotinas que se prendem com necessidades diárias de consumo de energia. Este comportamento cíclico pode ser visto na Figura 3.5, onde se verifica um comportamento semelhante nos dias úteis semanais e uma quebra no consumo de energia no fim-de-semana, devido à praticamente inexistente atividade industrial nesses dias.




Figura 3.5 - Diagrama de carga semanal.

Existem porém alguns fatores que desequilibram a periodicidade diária e semanal, fatores esses que estão relacionados essencialmente com a ocorrência de dias com rotinas distintas das verificadas normalmente, tais como, feriados, greves ou pontes. Se este tipo de dias acontecer nas proximidades de um fim-de-semana, dá-se origem a períodos mais alargados de redução da atividade económica e consequentemente a um menor consumo de energia. Na Figura 3.6 está representado um bom exemplo de um diagrama de carga semanal atípico, ou seja, com a existência de um dia feriado.




Figura 3.6 - Diagrama de carga de uma semana com feriado.

Em Portugal a gestão técnica dos equipamentos de produção de energia elétrica que constituem o sistema electroprodutor, para satisfazer o diagrama de carga verificado, é um dos desafios permanentes com que se debate a entidade gestora do SEN.

Para assegurar o fornecimento de energia elétrica, deve-se ter em conta as características das centrais disponíveis. Assim sendo, as centrais térmicas são geralmente pouco flexíveis, devendo operar de forma contínua por longos períodos de tempo, pelo que estão vocacionadas para assegurar a produção base. Para esta produção base contribuem também os produtores em regime especial (eólicos e fotovoltaicos), uma vez que a respetiva produção não está sujeita a “despacho”, mas sim sujeita à disponibilidade do recurso renovável utilizado.

As centrais hídricas por sua vez, tanto podem ser utilizadas para satisfazer a base do diagrama, como para satisfazer o consumo nas horas de cheia e ponta, uma vez que

apresentam um arranque relativamente rápido. Apresenta-se na Figura 3.7 o diagrama de carga da rede elétrica nacional verificado no dia 9 de Janeiro de 2013, com a potência entregue pelos diversos tipos de centrais para satisfazer a potência de consumo solicitada à rede.




Figura 3.7 - Diagrama de carga com os diversos tipos de produção [15].

Em Portugal a REN, disponibiliza diariamente o diagrama de carga da rede nacional de transporte de energia consumida por hora. Neste diagrama está representada a previsão do consumo de energia para o dia em questão, tal como o consumo real. Na Figura 3.8 apresenta-se o diagrama de carga para o dia 5 de Dezembro de 2012, um dia típico de Inverno.




Figura 3.8 - Diagrama de carga da Rede Nacional de Transporte de Portugal [15].

Relativamente ao consumo total abastecido pela REN, este tem vindo a crescer de 1996 até 2007, no entanto nos últimos anos verificou-se uma estagnação no consumo de energia em toda a Europa e em particular em Portugal, como se pode observar na Figura 3.9. Este abrandamento é consequência, não só devido ao abrandamento da economia e à crise económica europeia mas também devido aos esforços da União Europeia para solucionar o problema das alterações climáticas através da eficiência energética.




Figura 3.9 - Evolução do consumo de energia elétrica em Portugal [17].

Em 2012 a energia consumida em Portugal foi de 49.1 TWh, contraindo 2.9% face ao ano anterior, este valor representa um conjunto de vários tipos de produção líquida que é injetada na rede pelos centros de produção, entre eles produtores em regime ordinário (PRO) e produtores em regime especial (PRE) e o saldo de trocas internacionais, subtraindo naturalmente o consumo despendido na bombagem hidroelétrica. Na Figura 3.10, podemos observar, para o ano de 2011, a evolução semanal do abastecimento do consumo com discriminação do tipo de fonte primária de energia utilizada [15] [17].




Figura 3.10 - Evolução do consumo semanal em 2011 [15].

No ano de 2011 a potência máxima verificada no SEN foi de 9192 MW, no dia 24 de Janeiro às 19:45h. Os máximos anuais de potência solicitada à rede em Portugal, ocorrem normalmente nos dias mais frios de Inverno. No entanto tem vindo a observar-se um aumento significativo da potência no Verão, associado ao consumo de equipamentos de refrigeração, em particular de equipamentos de ar condicionado nos dias com temperaturas mais elevadas.

Na Figura 3.11 apresenta-se o valor máximo da ponta ocorrido em cada mês do ano de 2011. Este valor é bastante importante no planeamento da rede elétrica nacional, uma vez que terá que existir capacidade de fornecer pelo menos esta quantidade de energia aos consumidores.

Em 2012 a potência máxima atingiu os 8554 MW, valor que se situa abaixo do ano de 2011 e também do máximo histórico registado em 2010 de 9404 MW [15].






Figura 3.11 - Pontas na rede em 2011 [15].

A REN disponibiliza também na sua página diariamente o diagrama de carga ibérico, onde está representada a energia consumida em Portugal e Espanha de forma conjunta, este diagrama encontra-se representado na Figura 3.12.




Figura 3.12 - Diagrama de carga ibérico [15].

Na figura anterior, é possível verificar uma grande diferença em termos de consumo, relativamente ao diagrama de carga português, este fato está obviamente relacionado com a dimensão da rede elétrica de Espanha comparativamente com Portugal. De forma a ser

perceptível essa diferença apresenta-se na Figura 3.13 o diagrama de carga unicamente de Espanha do dia 12 de Dezembro de 2012, fornecido pela REE.




Figura 3.13 - Diagrama de carga da Rede Elétrica de Espanha no dia 12 de Dezembro 2012 (Inverno) [18].

No diagrama de carga estão presentes as rotinas diárias existentes em cada país, sendo que estas, no que diz respeito aos países da península Ibérica são bastante semelhantes, na Figura 3.14 pode observar-se o diagrama de carga da rede elétrica Portuguesa para o mesmo dia do ano da figura anterior, e verificar que as horas de ponta e vazio estão compreendidas no mesmo período de tempo.



Figura 3.14 - Diagrama de carga da rede elétrica Portuguesa no dia 12 de Dezembro 2012 (Inverno) [15].

No caso de países situados mais a norte de Europa, o diagrama sofre algumas alterações, nomeadamente na ponta da noite. Na Figura 3.15 podemos ver o diagrama de carga da rede elétrica de transporte de França no dia 12 de Dezembro de 2012, disponibilizado pela RTE, onde se observa a existência de uma ponta da noite menos prolongada no tempo, sendo que esta ponta acontece um pouco mais cedo relativamente a Portugal ou Espanha.




Figura 3.15 - Diagrama de carga da rede elétrica de transporte de França no dia 12 de Dezembro 2012 (Inverno) [19].

Como foi anteriormente referido, o diagrama de carga sofre algumas alterações consoante a altura do ano, tendo como análise duas estações do ano distintas (Inverno e Verão) e de forma a ser possível verificar as diferenças entre elas, pode observar-se na Figura 3.16 o diagrama de carga da rede de transporte de Portugal para o dia 4 de Julho de 2012.



Figura 3.16 - Diagrama de carga da rede elétrica portuguesa no dia 4 de Julho de 2012 (Verão) [15].

Através da comparação da figura anterior com a Figura 3.14 é possível verificar algumas diferenças, a mais visível reside no fato de não existir ponta da noite.

Nesta altura do ano é bastante perceptível a existência de um menor consumo de energia nas últimas horas do dia, isto deve-se ao fato de a temperatura descer ao longo do dia e ao contrário do que acontece no Inverno não existir tanta necessidade de utilização de aparelhos de climatização. O mesmo acontece em Espanha, como se pode visualizar na Figura 3.17.




Figura 3.17 - Diagrama de carga da Rede Elétrica de Espanha no dia 4 de Julho 2012 (Verão) [18].

Apesar da já referida queda do consumo nas horas mais tardias do dia, verifica-se também uma ligeira redução geral do consumo no Verão relativamente ao Inverno. Já em países localizados mais a norte da Europa, esta redução torna-se bastante significativa, como se pode observar na Figura 3.18, onde está representado o diagrama de carga da rede elétrica de transporte de França também para o dia 4 de Julho de 2012.




Figura 3.18 - Diagrama de carga da rede elétrica de transporte de França no dia 4 de Julho 2012 (Verão) [19].

Tendo como exemplo a Figura 3.15 em que o consumo máximo verificado neste dia se situava nos 90 GW (Inverno), verifica-se no Verão uma redução de cerca de 45% no consumo relativamente a um dia de Inverno. Este fato deve-se essencialmente às variações de temperatura durante o ano serem maiores nos países situados mais a norte da Europa.

Na Figura 3.18 também é possível verificar, tal como em Portugal e Espanha, a não existência de uma ponta da noite, sendo que ao nível do Verão o diagrama de carga diário nestes três países tem comportamentos semelhantes.

### 3.3 Tendência e Sazonalidade

Uma série temporal pode apresentar diversos tipos de características, tais como, nível, tendência, sazonalidade e ciclo. Quaisquer variações que não enquadrem essas características são consideradas aleatórias e, geralmente, provenientes de fatores externos.

A média ocorre quando os valores de uma série oscilam entre um valor médio constante, um ciclo acontece quando a série apresenta variações ascendentes e descendentes não regulares no tempo. A tendência existe quando a série apresenta uma propensão ascendente ou desce quando analisado um longo período de tempo. Finalmente a sazonalidade ocorre quando existem padrões cíclicos de variação que se repetem em intervalos relativamente constantes de tempo [7].

Os exemplos destas quatro características intrínsecas às séries temporais pode ser observado na Figura 3.19.




Figura 3.19 - Características de uma série temporal.

Quando se estuda o desenvolvimento de um qualquer fenómeno no tempo é possível observar situações em que se verificam sazonalidades ou seja, em que a série temporal se repete em intervalos de tempo fixos, apresentado um padrão de comportamento como por exemplo, a variação de temperatura ao longo do ano para um determinado país. Neste caso temos sempre uma fase do ano em que os dias apresentam temperaturas mais baixas e outra em que as temperaturas são elevadas, este padrão repete-se a cada período de um ano.

Podem existir também casos específicos em que um certo padrão de comportamento se repete em intervalos de tempo mais reduzidos, um destes casos é o consumo de energia elétrica. Este tipo de séries tem como característica a sazonalidade diária, ou seja, o padrão repete-se a cada 24 horas, sendo que dias homólogos têm comportamentos semelhantes em semanas diferentes como pode ser visto na Figura 3.20.




Figura 3.20 - Diagrama de carga semanal.

Na figura anterior pode ser vista também a diferença entre os dias úteis semanais e os dias de fim-de-semana, sendo que se verifica um natural decréscimo do consumo nestes dias. Essa situação origina outra característica na série do consumo de energia, sendo que esta apresenta também sazonalidade semanal, ou seja existe um padrão que se repete a cada sete dias (168 horas). Esta característica é facilmente observável na Figura 3.21, onde se dispõem quatro semanas consecutivas de consumo de energia elétrica em Portugal.




Figura 3.21 - Diagrama de carga da RNT no mês de Janeiro de 2012.

A sazonalidade de uma série temporal pode também ser classificada como sendo aditiva ou multiplicativa, ou seja, diz-se que a sazonalidade é aditiva se a variação sazonal é independente do nível geral da série. Já se a variação sazonal representar uma certa percentagem da proporção do nível da série, classifica-se como sazonalidade multiplicativa. Na Figura 3.22, podem observar-se duas séries temporais que apresentam sazonalidade aditiva e multiplicativa [20].




Figura 3.22 - Exemplo de séries temporais com sazonalidade aditiva e multiplicativa [20].

Outra característica das séries temporais a ter em conta é a tendência, relativamente ao consumo de energia elétrica em Portugal, um pouco ao contrário do que seria de esperar há alguns anos atrás, este tem vindo a estagnar como é possível observar na Figura 3.9. Apesar de no ano de 2010 se ter verificado um aumento significativo, a realidade é que a tendência desde 2006 tem sido para um ligeiro decréscimo do consumo de energia



elétrica. Na Figura 3.23 pode observa-se a variação anual do consumo de energia elétrica em Portugal, apresentada em percentagem.




Figura 3.23 - Variação anual do consumo de energia elétrica em Portugal [15].



---

## Capítulo 4

---

# Modelização

*Neste capítulo é feita uma abordagem à metodologia utilizada para efetuar a previsão do consumo de energia elétrica para um horizonte de curto prazo em Portugal continental. Apresentam-se as principais características que compõem a modelização, aprofundando os modelos que melhor se adaptam aos casos de estudo.*



## 4 Modelização

### 4.1 Introdução ao Modelo de Alisamento Exponencial de *Holt-Winters*

O modelo de amortecimento ou alisamento exponencial de *Holt-Winters* é um método univariado, como foi referido anteriormente, usa apenas a própria série de dados para realizar a previsão e devido à sua precisão e robustez é muito aplicado em várias áreas, tais como o consumo de energia elétrica, previsões de vendas, etc [1].

Contudo, antes de se realizar em previsões, é necessário estimar os valores iniciais do nível, tendência e de cada sazonalidade, há também que determinar os hiperparâmetros também conhecidos como constantes de amortecimento do modelo.

Este método é frequentemente utilizado para realizar previsão de séries temporais que possuem tendência e sazonalidade, podendo este ser formulado de maneira aditiva ou multiplicativa os quais são apresentados nos pontos seguintes. A primeira, é mais indicada para séries que apresentem variância constante ao longo do tempo (sazonalidade aditiva). A segunda, adapta-se a séries cuja variância cresce em conjunto com o nível da série (sazonalidade multiplicativa) [13].

#### 4.1.1 Modelo *Holt-Winters* Aditivo

Este modelo é adequado para séries temporais que possuem um efeito de tendência aditiva e um efeito sazonal aditivo sobreposto.

Considerando a série  $X_t$ , tendo em conta que esta possui apenas um ciclo e apresenta sazonalidade aditiva, esta pode ser modelizada da seguinte forma:

$$X_t = S_t + kT_t + I_t + \varepsilon_t \quad (4.1)$$

onde,  $S_t$  se refere ao nível,  $T_t$  à tendência,  $I_t$  ao fator sazonal,  $k$  ao número das observações e finalmente  $\varepsilon_t$  representa o resíduo aleatório [13].

Os parâmetros anteriormente referidos (nível, tendência e sazonalidade) devem ser atualizados a cada instante de tempo. Para tal, utilizam-se as seguintes equações:

- Nível

$$S_t = \alpha (X_t - I_{t-s}) + (1 - \alpha)(S_{t-1} + T_{t-1}) \quad (4.2)$$

- Tendência

$$T_t = \gamma (S_t - S_{t-1}) + (1 - \gamma)T_{t-1} \quad (4.3)$$

- Sazonalidade

$$I_t = \delta (X_t - S_t) + (1 - \delta)I_{t-s} \quad (4.4)$$

Nas equações acima, considera-se  $X_t$  como sendo a observação no período  $t$ , onde  $\alpha$ ,  $\gamma$  e  $\delta$  representam constantes de amortecimento com valores compreendidos entre 0 e 1 [1].

Na equação (4.2), a subtração da componente sazonal (estimada  $s$  instantes atrás) à observação  $X_t$  é feita de forma a retirar desta observação a sazonalidade, tendo como objetivo possibilitar que o processo de atualização da componente de nível seja baseada na estimativa dela mesma e da tendência.

Na expressão (4.4), é realizada a atualização do índice sazonal para a estação correspondente ao instante  $t$  (avaliado pela última vez  $s$  instantes atrás) agregando a avaliação mais recente (para o instante  $t$ ) do efeito sazonal (calculado através da diferença entre a observação e o nível para esse instante  $t$ ).

Os valores de previsão para instantes futuros, sendo  $k$  o período a prever, são determinados através da seguinte equação [1]:

$$\hat{X}_t(k) = S_t + kT_t + I_{t-s+k} \quad (4.5)$$

#### 4.1.2 Modelo *Holt-Winters* Multiplicativo

Este modelo é adequado a séries em que a amplitude das variações sazonais é proporcional ao nível da série.

Considerando a série  $X_t$ , tendo em conta que esta possui apenas um ciclo e apresenta sazonalidade multiplicativa, esta pode ser modelizada da seguinte forma:

$$X_t = (S_t + kT_t)I_t + \varepsilon_t \quad (4.6)$$

Sendo os coeficientes apresentados na equação anterior iguais às definições descritas no ponto anterior. Estes parâmetros (nível, tendência e sazonalidade) devem ser atualizados a cada instante de tempo. Para tal, utilizam-se as seguintes equações:

- Nível

$$S_t = \alpha \left( \frac{X_t}{I_{t-s}} \right) + (1 - \alpha)(S_{t-1} + T_{t-1}) \quad (4.7)$$

- Tendência

$$T_t = \gamma (S_t - S_{t-1}) + (1 - \gamma)T_{t-1} \quad (4.8)$$

- Sazonalidade

$$I_t = \delta \left( \frac{X_t}{S_t} \right) + (1 - \delta)I_{t-s} \quad (4.9)$$

Este modelo assume que a tendência aditiva é estimada através do somatório do passo local amortecido e pelas sucessivas diferenças amortecidas,  $S_t - S_{t-1}$ , do nível local  $S_t$ . O índice sazonal local,  $I_t$ , é estimado pela razão amortecida do valor observado,  $X_t$ , e o nível,  $S_t$  [1].

As previsões para instantes futuros são determinados através de:

$$\hat{X}_t(k) = (S_t + kT_t)I_{t-s+k} \quad (4.10)$$

## 4.2 Modelos de Alisamento Exponencial de *Holt-Winters* com sazonalidade simples

Os modelos de alisamento exponencial apresentados anteriormente são modelos padrão, sendo que existe a possibilidade de construir modelos combinando vários tipos de sazonalidade e tendência. Na Tabela 4.1, pode observar-se as equações gerais de modelos com combinações de tendência aditiva, aditiva amortecida, multiplicativa e multiplicativa amortecida com sazonalidade aditiva e multiplicativa.

Tabela 4.1- Métodos de alisamento exponencial [21].

Tendência	Sazonalidade		
	(Sem sazonalidade)	Aditiva	Multiplicativa
(Sem tendência)	$S_t = \alpha X_t + (1 - \alpha)S_{t-1}$ $\hat{X}_t(m) = S_t$	$S_t = \alpha(X_t - I_{t-p}) + (1 - \alpha)S_{t-1}$ $I_t = \delta(X_t - S_t) + (1 - \delta)I_{t-p}$ $\hat{X}_t(m) = S_t + I_{t-p+m}$	$S_t = \alpha(X_t / I_{t-p}) + (1 - \alpha)S_{t-1}$ $I_t = \delta(X_t / S_t) + (1 - \delta)I_{t-p}$ $\hat{X}_t(m) = S_t I_{t-p+m}$
	$S_t = S_{t-1} + \alpha e_t$ $\hat{X}_t(m) = S_t$	$S_t = S_{t-1} + \alpha e_t$ $I_t = I_{t-p} + \delta(1 - \alpha)e_t$ $\hat{X}_t(m) = S_t + I_{t-p+m}$	$S_t = S_{t-1} + \alpha e_t / I_{t-p}$ $I_t = I_{t-p} + \delta(1 - \alpha)e_t / S_t$ $\hat{X}_t(m) = S_t I_{t-p+m}$
Aditiva	$S_t = \alpha X_t + (1 - \alpha)(S_{t-1} + T_{t-1})$ $T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)T_{t-1}$ $\hat{X}_t(m) = S_t + mT_t$	$S_t = \alpha(X_t - I_{t-p}) + (1 - \alpha)(S_{t-1} + T_{t-1})$ $T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)T_{t-1}$ $I_t = \delta(X_t - S_t) + (1 - \delta)I_{t-p}$ $\hat{X}_t(m) = S_t + mT_t + I_{t-p+m}$	$S_t = \alpha(X_t / I_{t-p}) + (1 - \alpha)(S_{t-1} + T_{t-1})$ $T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)T_{t-1}$ $I_t = \delta(X_t / S_t) + (1 - \delta)I_{t-p}$ $\hat{X}_t(m) = (S_t + mT_t)I_{t-p+m}$
	$S_t = S_{t-1} + T_{t-1} + \alpha e_t$ $T_t = T_{t-1} + \alpha \gamma e_t$ $\hat{X}_t(m) = S_t + mT_t$	$S_t = S_{t-1} + T_{t-1} + \alpha e_t$ $T_t = T_{t-1} + \alpha \gamma e_t$ $I_t = I_{t-p} + \delta(1 - \alpha)e_t$ $\hat{X}_t(m) = S_t + mT_t + I_{t-p+m}$	$S_t = S_{t-1} + T_{t-1} + \alpha e_t / I_{t-p}$ $T_t = T_{t-1} + \alpha \gamma e_t / I_{t-p}$ $I_t = I_{t-p} + \delta(1 - \alpha)e_t / S_t$ $\hat{X}_t(m) = (S_t + mT_t)I_{t-p+m}$
Aditiva Amortecida	$S_t = \alpha X_t + (1 - \alpha)(S_{t-1} + \phi T_{t-1})$ $T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)\phi T_{t-1}$ $\hat{X}_t(m) = S_t + \sum_{i=1}^m \phi^i T_t$	$S_t = \alpha(X_t - I_{t-p}) + (1 - \alpha)(S_{t-1} + \phi T_{t-1})$ $T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)\phi T_{t-1}$ $I_t = \delta(X_t - S_t) + (1 - \delta)I_{t-p}$ $\hat{X}_t(m) = S_t + \sum_{i=1}^m \phi^i T_t + I_{t-p+m}$	$S_t = \alpha(X_t / I_{t-p}) + (1 - \alpha)(S_{t-1} + \phi T_{t-1})$ $T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)\phi T_{t-1}$ $I_t = \delta(X_t / S_t) + (1 - \delta)I_{t-p}$ $\hat{X}_t(m) = (S_t + \sum_{i=1}^m \phi^i T_t)I_{t-p+m}$
	$S_t = S_{t-1} + \phi T_{t-1} + \alpha e_t$ $T_t = \phi T_{t-1} + \alpha \gamma e_t$ $\hat{X}_t(m) = S_t + \sum_{i=1}^m \phi^i T_t$	$S_t = S_{t-1} + \phi T_{t-1} + \alpha e_t$ $T_t = \phi T_{t-1} + \alpha \gamma e_t$ $I_t = I_{t-p} + \delta(1 - \alpha)e_t$ $\hat{X}_t(m) = S_t + \sum_{i=1}^m \phi^i T_t + I_{t-p+m}$	$S_t = S_{t-1} + \phi T_{t-1} + \alpha e_t / I_{t-p}$ $T_t = \phi T_{t-1} + \alpha \gamma e_t / I_{t-p}$ $I_t = I_{t-p} + \delta(1 - \alpha)e_t / S_t$ $\hat{X}_t(m) = (S_t + \sum_{i=1}^m \phi^i T_t)I_{t-p+m}$
Multiplicativa	$S_t = \alpha X_t + (1 - \alpha)(S_{t-1} R_{t-1})$ $R_t = \gamma(S_t / S_{t-1}) + (1 - \gamma)R_{t-1}$ $\hat{X}_t(m) = S_t R_t^m$	$S_t = \alpha(X_t - I_{t-p}) + (1 - \alpha)S_{t-1} R_{t-1}$ $R_t = \gamma(S_t / S_{t-1}) + (1 - \gamma)R_{t-1}$ $I_t = \delta(X_t - S_t) + (1 - \delta)I_{t-p}$ $\hat{X}_t(m) = S_t R_t^m + I_{t-p+m}$	$S_t = \alpha(X_t / I_{t-p}) + (1 - \alpha)S_{t-1} R_{t-1}$ $R_t = \gamma(S_t / S_{t-1}) + (1 - \gamma)R_{t-1}$ $I_t = \delta(X_t / S_t) + (1 - \delta)I_{t-p}$ $\hat{X}_t(m) = (S_t R_t^m)I_{t-p+m}$
	$S_t = S_{t-1} R_{t-1} + \alpha e_t$ $R_t = R_{t-1} + \alpha \gamma e_t / S_{t-1}$ $\hat{X}_t(m) = S_t R_t^m$	$S_t = S_{t-1} R_{t-1} + \alpha e_t$ $R_t = R_{t-1} + \alpha \gamma e_t / S_{t-1}$ $I_t = I_{t-p} + \delta(1 - \alpha)e_t$ $\hat{X}_t(m) = S_t R_t^m + I_{t-p+m}$	$S_t = S_{t-1} R_{t-1} + \alpha e_t / I_{t-p}$ $R_t = R_{t-1} + (\alpha \gamma e_t / S_{t-1}) / I_{t-p}$ $I_t = I_{t-p} + \delta(1 - \alpha)e_t / S_t$ $\hat{X}_t(m) = (S_t R_t^m)I_{t-p+m}$
Multiplicativa Amortecida	$S_t = \alpha X_t + (1 - \alpha)(S_{t-1} R_{t-1}^\phi)$ $R_t = \gamma(S_t / S_{t-1}) + (1 - \gamma)R_{t-1}^\phi$ $\hat{X}_t(m) = S_t R_t^{\sum_{i=1}^m \phi^i}$	$S_t = \alpha(X_t - I_{t-p}) + (1 - \alpha)S_{t-1} R_{t-1}^\phi$ $R_t = \gamma(S_t / S_{t-1}) + (1 - \gamma)R_{t-1}^\phi$ $I_t = \delta(X_t - S_t) + (1 - \delta)I_{t-p}$ $\hat{X}_t(m) = S_t R_t^{\sum_{i=1}^m \phi^i} + I_{t-p+m}$	$S_t = \alpha(X_t / I_{t-p}) + (1 - \alpha)(S_{t-1} R_{t-1}^\phi)$ $R_t = \gamma(S_t / S_{t-1}) + (1 - \gamma)R_{t-1}^\phi$ $I_t = \delta(X_t / S_t) + (1 - \delta)I_{t-1}$ $\hat{X}_t(m) = (S_t R_t^{\sum_{i=1}^m \phi^i})I_{t-p+m}$
	$S_t = S_{t-1} R_{t-1}^\phi + \alpha e_t$ $R_t = R_{t-1}^\phi + \alpha \gamma e_t / S_{t-1}$ $\hat{X}_t(m) = S_t R_t^{\sum_{i=1}^m \phi^i}$	$S_t = S_{t-1} R_{t-1}^\phi + \alpha e_t$ $R_t = R_{t-1}^\phi + \alpha \gamma e_t / S_{t-1}$ $I_t = I_{t-p} + \delta(1 - \alpha)e_t$ $\hat{X}_t(m) = S_t R_t^{\sum_{i=1}^m \phi^i} + I_{t-p+m}$	$S_t = S_{t-1} R_{t-1}^\phi + \alpha e_t / I_{t-p}$ $R_t = R_{t-1}^\phi + (\alpha \gamma e_t / S_{t-1}) / I_{t-p}$ $I_t = I_{t-p} + \delta(1 - \alpha)e_t / S_t$ $\hat{X}_t(m) = (S_t R_t^{\sum_{i=1}^m \phi^i})I_{t-p+m}$



Apesar das diferentes combinações estes modelos são apropriados para previsão de séries temporais que apresentem um único padrão sazonal/ciclo. No ponto 3.3 desta dissertação, foram apresentadas as características da série do consumo de energia nacional, sendo que uma dessas características é a existência de dois padrões sazonais por ciclo. Dessa forma, estes modelos anteriormente explicitados podem não ser os mais indicados para este tipo de séries temporais, sendo que serão utilizados modelos de alisamento exponencial com dupla sazonalidade, tendo estes por base os modelos da Tabela 4.1.

### 4.3 Modelos de Alisamento Exponencial de *Holt-Winters* com dupla sazonalidade

As séries com variação cíclica ou sazonal, são difíceis de modelizar através do modelo de *Holt-Winters* de alisamentos exponencial padrão, porque contêm mais do que um ciclo sazonal. O modelo de *Holt-Winters* com dupla sazonalidade é aplicável quando existem dois padrões de sazonalidade na série temporal, como é o caso da série do consumo de energia elétrica. Esta série apresenta um ciclo sazonal diário, que representa o mesmo perfil de carga em cada dia semanal, e um outro semanal, que irá representar um perfil semelhante entre as semanas [1].

A formulação matemática do modelo incorpora dois índices de sazonalidade distintos designados por,  $D_t$  e  $W_t$ , em que o primeiro representará o ciclo diário e o segundo o ciclo semanal com períodos  $s_1$  e  $s_2$  respetivamente.

#### 4.3.1 Modelo de *Holt-Winters* Multiplicativo

Considerando a série  $X_t$ , tendo em conta que esta possui dois ciclos sazonais e apresenta sazonalidade multiplicativa, esta pode ser modelizada da seguinte forma:

$$X_t = (S_t + KT_t)D_tW_t + \varepsilon_t \quad (4.17)$$

Sendo os coeficientes apresentados na equação seguinte iguais às definições descritas no ponto anterior. Estes parâmetros (nível, tendência e sazonalidade) devem ser atualizados a cada instante de tempo. Para tal, utilizam-se as seguintes equações [1]:

- Nível

$$S_t = \alpha \left( \frac{X_t}{D_{t-s_1} W_{t-s_2}} \right) + (1 - \alpha)(S_{t-1} + T_{t-1}) \quad (4.18)$$

- Tendência

$$T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)T_{t-1} \quad (4.19)$$

- Sazonalidade 1

$$D_t = \delta \left( \frac{X_t}{S_t W_{t-s_2}} \right) + (1 - \delta)D_{t-s_1} \quad (4.20)$$

- Sazonalidade 2

$$W_t = \omega \left( \frac{X_t}{S_t D_{t-s_1}} \right) + (1 - \omega)W_{t-s_2} \quad (4.21)$$

Os valores de previsão para instantes futuros, sendo  $k$  o valor do período a prever, são determinados através da seguinte equação:

$$\hat{X}_t(k) = (S_t + kT_t)D_{t-s_1+k}W_{t-s_2+k} \quad (4.22)$$

O modelo multiplicativo é composto por quatro constantes de amortecimento,  $\alpha, \gamma, \delta$  e  $\omega$ . Sendo que, a resolução deste modelo passa pela otimização das equações anteriores por validação destas mesmas constantes, compreendidas entre 0 e 1.

### 4.3.2 Modelo de *Holt-Winters* com Tendência Suavizada

Nesta variante do método, introduz-se a possibilidade de suavizar ou amortecer a tendência, adicionando ao modelo um quarto parâmetro de amortecimento,  $\phi$ , tal que  $\gamma \leq \phi \leq 1$ , sendo as equações de atualização dadas por [22]:

- Nível

$$S_t = \alpha \left( \frac{X_t}{D_{t-s_1} W_{t-s_2}} \right) + (1 - \alpha)(S_{t-1} + \phi T_{t-1}) \quad (4.23)$$

- Tendência

$$T_t = \gamma(S_t - S_{t-1}) + (\phi - \gamma)T_{t-1} \quad (4.24)$$

- Sazonalidade 1

$$D_t = \delta \left( \frac{X_t}{S_t W_{t-s_2}} \right) + (1 - \delta)D_{t-s_1} \quad (4.25)$$

- Sazonalidade 2

$$W_t = \omega \left( \frac{X_t}{S_t D_{t-s_1}} \right) + (1 - \omega) W_{t-s_2} \quad (4.26)$$

Os valores de previsão para instantes futuros, sendo  $k$  o valor do período a prever, são determinados através da seguinte equação:

$$\hat{X}_t(k) = (S_t + (\sum_{i=1, \dots, k} \phi^i) \times T_t) D_{t-s_1+k} W_{t-s_2+k} \quad (4.27)$$

O modelo com tendência suavizada é composto por cinco constantes de amortecimento,  $\alpha, \gamma, \delta, \omega$  e  $\phi$ . Sendo que, a resolução deste modelo passa pela otimização das equações anteriores por alteração destas mesmas constantes.

### 4.3.3 Modelo de *Holt-Winters* com Tendência Suavizada e Erros Estruturados

Outra variante do modelo de *Holt-Winters*, consiste na introdução de mais um parâmetro,  $\lambda$ , tal que  $0 \leq \lambda \leq 1$ , que permite sua modulação seja efetuada com maior precisão, aumentando também a complexidade do modelo. O processo de atualização dos parâmetros, realiza-se através das equações (4.23), (4.24), (4.25) e (4.26) apresentados nos pontos anteriores.

Os valores de previsão para instantes futuros, sendo  $k$  o valor do período a prever, são determinados através da seguinte equação [23]:

$$\hat{X}_t(k) = (S_t + (\sum_{i=1, \dots, k} \phi^i) \times T_t) D_{t-s_1+k} W_{t-s_2+k} + \lambda^k (X_t - ((S_t + \phi \times T_t) D_{t-s_1} W_{t-s_2})) \quad (4.28)$$

O modelo com tendência suavizada e erros estruturados é composto por seis parâmetros de amortecimento,  $\alpha, \gamma, \delta, \omega, \phi$  e  $\lambda$ . Sendo que, a resolução deste modelo passa pela otimização das equações anteriores por alteração destes mesmo parâmetros.

## 4.4 Valores Iniciais dos Parâmetros

Todos os modelos descritos anteriormente terão que ser inicializados, ou seja, será necessário calcular os valores iniciais das equações de atualização  $S_t(0)$ ,  $T_t(0)$ ,  $D_t(0)$  e  $W_t(0)$  que são determinados através do procedimento descrito de seguida. Este procedimento é apresentado para o caso dos modelos com dois ciclos sazonais, um ciclo diário e um ciclo semanal [24].

A série temporal  $X_t(0)$  pode ser escrita na forma matricial, onde as linhas representam o ciclo menor (dia,  $s_1 = 24$ ) e as colunas o ciclo maior como se segue:

$$\begin{matrix} X_{1,1}^* & X_{1,2}^* & \dots & X_{1,s_1}^* \\ X_{2,1}^* & X_{2,2}^* & \dots & X_{2,s_1}^* \\ X_{3,1}^* & X_{3,2}^* & \dots & X_{3,s_1}^* \\ \dots & \dots & \dots & \dots \\ X_{I,1}^* & X_{I,2}^* & \dots & X_{I,s_1}^* \end{matrix}$$

Existem  $I$  dias completos de dados horários históricos, ou seja, o número de ciclos diários provenientes dos dados históricos. Deste modo calcula-se:

- Passo 1: Médias “diárias”

$$\bar{X}_i = \frac{\sum_{j=1}^{s_1} X_{i,j}}{s_1}, \text{ para } i = 1, \dots, I \quad (4.29)$$

Sendo  $i$  os dias e  $j$  as horas do ciclo.

- Passo 2: Fatores dos ciclos diários grosseiros

$$\begin{matrix} D_{1,1}^* & D_{1,2}^* & \dots & D_{1,s_1}^* \\ D_{2,1}^* & D_{2,2}^* & \dots & D_{2,s_1}^* \\ D_{3,1}^* & D_{3,2}^* & \dots & D_{3,s_1}^* \\ \dots & \dots & \dots & \dots \\ D_{I,1}^* & D_{I,2}^* & \dots & D_{I,s_1}^* \end{matrix}$$

Onde,

$$D_{i,j}^* = \frac{X_{i,j}}{\bar{X}_i}, \text{ para } j = 1, \dots, s_1 \text{ e } i = 1, \dots, I \quad (4.30)$$

- Passo 3: Fatores dos ciclos diários

$$D_j^* = \frac{\sum_{i=1}^I D_{i,j}^*}{I}, \text{ para } j = 1, \dots, s_1 \quad (4.31)$$

- Passo 4: Fatores dos ciclos diários normalizados

$$D_j = \left( \frac{D_j^*}{\sum_{j=1}^{s_1} D_j^*} \right) \times s_1, j = 1, \dots, s_1 \quad (4.32)$$

- Passo 5: Estimativas iniciais para os parâmetros do modelo

$$S_t(0) \cong \bar{X}_1 \quad (4.33)$$

$$T_t(0) \cong \frac{\bar{X}_2 - \bar{X}_1}{s_2} \quad (4.34)$$

$$D_j(0) \cong D_j, \text{ para } j = 1, \dots, s_1 \quad (4.35)$$

$$W_j(0) \cong W_j, \text{ para } j = 1, \dots, s_2 \quad (4.36)$$

É de salientar que para os valores iniciais dos parâmetros do modelo para o ciclo semanal,  $W_t(0)$  para  $j = 1, \dots, s_2$ , o procedimento é idêntico (segue-se os passos 1 a 4). Neste caso, os dados passam a ser organizados numa matriz cujas linhas são as horas das semanas (dimensão  $s_2$ ) [24].

Os valores estimados do nível e da tendência iniciais (Passo 5), são determinados de acordo com os valores médios do ciclo semanal.

## 4.5 Medidas de Erro de Previsão

A precisão de um método de previsão pode ser medida através de diversas medidas de erro. Considera-se como erro a diferença entre o valor observado e a previsão no mesmo instante  $t$ , descrito pela equação [25]:

$$\varepsilon_t = X_t - \hat{X}_t \quad (4.37)$$

O valor do erro médio, pode adotar valores negativos assim como valores positivos, porém o critério de avaliação é o de que quanto mais próximo do valor zero, melhor será o método escolhido, o erro médio obtém-se pela equação:

$$EM = \frac{1}{n} \sum_{i=1}^n \varepsilon_t \quad (4.38)$$

Outra medida de erro utilizada nesta dissertação foi o erro médio absoluto. Quando mais próximo do zero for este erro melhor será a precisão do método escolhido para efetuar previsões, o seu cálculo obedece à expressão:

$$EMA = \frac{1}{n} \sum_{i=1}^n |\varepsilon_t| \quad (4.39)$$

O erro médio quadrático: É definido como a soma dos quadrados dos desvios, dividida pelo número de observações, este tipo de erro enfatiza os erros de maior valor, conforme a seguinte expressão:

$$QME = \frac{1}{n} \sum_{i=1}^n \varepsilon_t^2 \quad (4.40)$$

Já o erro percentual médio absoluto é outro dos indicadores quem tem grande importância, onde verifica a relação entre o valor observado e o valor de previsão, de

forma que este resultado seja visto como positivo. Avalia-se que quanto mais próximo de zero, mais adequado será o método de previsão, refira-se ainda que este é um dos indicadores mais utilizados para aferir a qualidade de um modelo proposto, bem como para estabelecer comparações entre diferentes modelos. É traduzido pela expressão:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\varepsilon_t}{X_t} \right| \times 100 \quad (4.41)$$

Além dessas medidas de erro, existe outro parâmetro de grande importância na análise do ajuste do modelo à série de dados. O coeficiente de determinação, também conhecido como  $R^2$  é uma medida percentual de explicação do modelo. Ou seja, esta estatística mostra a fração da variabilidade da série que o método utilizado consegue explicar. Um valor  $R^2$  próximo de zero indica um modelo de ajuste pobre, enquanto um valor próximo da unidade indica um bom ajuste. Essa estatística pode ser determinada recorrendo à seguinte equação [26]:

$$R^2 = 1 - \frac{\sum_{t=1}^n (X_t - \hat{X}_t)^2}{\sum_{t=1}^n (X_t - \bar{X})^2} \quad (4.42)$$

Outra estatística de teste bastante importante na análise do ajuste do modelo e da qualidade da previsão, é o teste U Theil que permite uma comparação relativa a métodos formais de previsão com método cândido e pelo fato de envolver no seu cálculo os quadrados dos erros, traduz também a importância dos grandes erros, aos quais é dado um maior peso do que aos pequenos.

A Estatística de teste U Theil é uma medida relativa ao erro de previsão e é dada por:

$$U = \sqrt{\frac{\sum_{t=1}^{n-1} \left( \frac{\hat{X}_{t+1} - X_{t+1}}{X_t} \right)^2}{\sum_{t=1}^{n-1} \left( \frac{X_{t+1} - X_t}{X_t} \right)^2}} \quad (4.43)$$

Quando a previsão  $\hat{X}_{t+1}$  é exatamente igual ao valor observado  $X_{t+1}$ , o valor U é igual a zero. Quando  $X_{t+1}$  e  $\hat{X}_{t+1}$  são diferentes, a previsão não está representada com perfeição, o valor de estatística U aumenta e pode apresentar valores maiores que um.

Desta forma, da qualidade de um determinado modelo supostamente representativo da série histórica de dados está dependente na medida de erro adotada para efetuar a validação. Assim, de acordo com o exposto em cima, tem-se que [27]:

- U = 1 : o método natural é tão bom quanto a técnica de previsão que está a ser avaliada.

- $U < 1$  : o método de previsão em estudo é melhor do que o método natural. Quanto menor a estatística  $U$ , mais adequado será o método em relação ao método natural.
- $U > 1$  : não existe nenhuma razão em utilizar métodos de previsão, já que o uso de um método natural produzirá melhores resultados.

## 4.6 Intervalo de Confiança

É importante conhecer o intervalo de confiança, uma vez que o valor real do consumo pode estar dentro deste intervalo de previsão, assumindo-se dessa forma um certo nível de confiança para o intervalo previsto.

O estabelecimento de intervalos de confiança realizados sobre as previsões efetuadas, considerando um passo à frente, é calculado pela expressão [28]:

$$\left( \hat{X}_{t+1} - Z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}}; \hat{X}_{t+1} + Z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}} \right) \quad (4.44)$$

É de salientar que, o intervalo de confiança será determinado recorrendo à distribuição normal  $Z_{\alpha/2}$  tendo em conta os dados disponíveis.

Quando se pretende determinar o intervalo de confiança para a previsão, considerando  $k$  passos à frente, tem-se então:

$$\left( \hat{X}_{t+k} - Z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}}; \hat{X}_{t+k} + Z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}} \right) \quad (4.45)$$





---

## Capítulo 5

---

### Casos de Estudo

*Neste capítulo são apresentados os diversos casos de estudo, tendo sempre como ponto de partida a base teórica apresentada nos capítulos anteriores. São apresentados os resultados obtidos pela aplicação dos diversos modelos e feitas algumas comparações entre os mesmos, de forma a que seja possível aferir, dos modelos estudados, qual o mais adequado para efetuar a previsão do consumo de energia em Portugal.*



## 5 Casos de Estudo

### 5.1 Tratamento das Séries de Dados

Uma vez que, para a elaboração desta dissertação eram necessários dados de consumo geral (doméstico e industrial) de energia elétrica verificada em Portugal, foram feitas algumas pesquisas de forma a obter os valores pretendidos. Estes valores foram gentilmente fornecidos pela empresa nacional REN, através de meios informáticos como a sua página da Internet [15], mas também através de outros pedidos, por correio eletrónico, esclarecendo que estes seriam para utilização e estudo no âmbito desta dissertação.

A série de dados fornecida corresponde ao período entre o ano de 2010 e 2012, a série contém os valores de energia consumida em MWh, sendo que os valores se encontram representados em intervalos de 15 minutos.

Foi efetuado o tratamento destes dados, de forma a detetar e corrigir valores nulos ou adulterados foram também substituídos os dias feriados por dias homólogos da semana seguinte ou anterior, de forma a diminuir o erro do modelo e posteriormente fazer a previsão do consumo de energia elétrica.

A série de valores foi também transformada em intervalos de 30 minutos e 60 minutos através da ferramenta computacional *Matlab* na versão R2010a, estes valores são obtidos efetuando a média dos dados originalmente fornecidos (15 minutos).

### 5.2 Aplicação dos Modelos à Serie de Dados

Como foi dito anteriormente no capítulo 1, a capacidade de armazenamento de energia é um dos grandes problemas da engenharia atual, a conjuntura no que diz respeito a esse armazenamento ainda não está ao nível que seria necessário para tornar rentável este processo em grande escala. Desta forma, é fundamental para que a energia esteja disponível, na altura em que seja necessária a sua utilização, que a operação da rede de energia elétrica seja planeada com base na informação histórica.

Para a resolução deste problema, foram analisados nesta dissertação vários modelos de previsão e foram estudados com maior detalhe três modelos de *Holt-Winters*:

- Modelo de *Holt-Winters* multiplicativo;

- Modelo de *Holt-Winters* multiplicativo com tendência suavizada;
- Modelo de *Holt-Winters* multiplicativo com Tendência suavizada e erros estruturados.

Estes modelos foram desenvolvidos na íntegra, sem recorrer a qualquer *software* de simulação existente no mercado, em que os modelos são apresentados sem que haja possibilidade de alterar a estrutura e que por isso mesmo, apresentam algumas limitações.

Após alguma pesquisa relativamente à aplicação de modelos deste tipo, a escolha dos programas de implementação recaiu sobre as ferramentas computacionais *Matlab*® na versão R2010a e também no *Microsoft*® *Office Excell*® 2007.

O desenvolvimento destes três modelos foi efetuado com base na teoria apresentada no capítulo 4, sendo que inicialmente foi necessário obter os valores de inicialização das diversas equações (ver 4.4). Em seguida, foram construídos os modelos para vários intervalos temporais e efetuadas diversas simulações de forma a otimizar as constantes de amortecimento, através do critério da minimização da soma do erro percentual absoluto médio (MAPE). Foi também testado a minimização da soma de outros tipos de erros, sendo que os melhores resultados foram obtidos quando se procedeu a minimização do MAPE. Após a obtenção das constantes de amortecimento, foi realizada a previsão para um horizonte temporal de 7 dias. Estes 7 dias foram previstos sem que haja, nas horas que entretanto decorreram após o início da previsão, qualquer atualização das várias equações que compõe o modelo.

A precisão dos métodos de previsão pode ser mensurada através de diversas medidas de erro. O critério seguido nesta dissertação é o de verificar quais dos métodos produzem resultados mais próximos de zero, para o erro médio absoluto (EMA), erro médio quadrático (QME) e erro percentual absoluto médio (MAPE).

Cada um dos três modelos foi construído com três intervalos de tempo da série de dados distintos, sendo eles:

- 1 Ano com 8762 observações (hora a hora);
- 1 Ano com 17524 observações (30 em 30 min);
- 2 Anos 17524 observações (hora hora).

## 5.2.1 Modelo de *Holt-Winters* Multiplicativo

### 5.2.1.1 Série de 1 ano de dados com 8762 observações

Nesta fase foi desenvolvido o modelo com uma série de dados de um ano (Outubro de 2011 até Outubro de 2012) e com valores horários (8762 observações), com o objetivo de prever as sete semanas seguintes individualmente. O modelo ajustado apresenta as seguintes medidas de erro (QME, MAPE e EMA) e de qualidade do ajuste  $U_{theil}$  e  $R^2$ , para as 8762 observações do ajuste.

Tabela 5.1 - Medidas de erro e de qualidade do ajuste do modelo.

Modelo	$R^2$	U	EMA	QME	MAPE [%]
HW multiplicativo	1	0,0001	0,02388	0,0007	0,0004

Em seguida foi necessário otimizar o modelo a cada semana que se pretendia prever, obtendo dessa forma sete valores diferentes para cada constante de amortecimento. Estes valores podem ser vistos na tabela seguinte.

Tabela 5.2 - Valores das constantes de amortecimento ao longo das sete semanas previstas.

Par.	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Semana 6	Semana 7	Média
$\alpha$	0,9999953	0,9999950	0,9999943	0,9999939	0,9999936	0,9999935	0,9999933	0,9999941
$\gamma$	0,0000223	0,0000225	0,0000227	0,0000228	0,0000229	0,0000230	0,0000230	0,0000227
$\delta$	0,3758671	0,3758673	0,3758673	0,3758674	0,3758671	0,3758678	0,3758674	0,3758674
$\omega$	0,4174399	0,4174428	0,4174457	0,4174462	0,4174463	0,4174467	0,4174466	0,4174449

Seguidamente apresenta-se o gráfico e a tabela resumo com a evolução dos vários erros de previsão calculados ao longo das sete semanas, tal como os gráficos das semanas com maior e menor erro de previsão (MAPE).




Figura 5.1 - Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas.

Tabela 5.3 - Valores dos erros, para as sete semanas previstas.

Semana	MAPE	QME	EMA	U
1	11,88%	477345	608,7	0,8080
2	11,58%	451056	591,9	0,7972
3	11,96%	473249	616,6	0,8017
4	12,06%	502901	650,0	0,9623
5	12,64%	596304	705,5	0,9653
6	15,30%	1039441	898,8	0,9972
7	13,28%	768085	787,9	0,9751




Figura 5.2 - Valores previstos relativos à melhor semana prevista (segunda semana).




Figura 5.3 - Intervalo de confiança de 95% para a melhor semana prevista.




Figura 5.4 - Valores previstos relativos à pior semana prevista (sexta semana).




Figura 5.5 - Intervalo de confiança de 95% para a pior semana prevista.

### 5.2.1.2 Série de 1 ano de dados com 17524 observações

Foi desenvolvido também o modelo com uma série de dados de um ano (Outubro de 2011 até Outubro de 2012) mas com valores de 30 em 30 minutos (17524 observações), com o objetivo de prever as sete semanas seguintes individualmente. O modelo ajustado apresenta as medidas de erro e de qualidade do ajuste expostas na tabela seguinte, para as 17524 observações.



Tabela 5.4 - Medidas de erro e de qualidade do ajuste do modelo.

Modelo	$R^2$	U	EMA	QME	MAPE [%]
HW multiplicativo	1	0,0001	0,01195	0,0001868	0,0002

Em seguida foi necessário otimizar o modelo a cada semana que se pretendia prever, obtendo dessa forma sete valores diferentes para cada constante de amortecimento. Estes valores podem ser vistos na tabela seguinte.

Tabela 5.5 - Valores das constantes de amortecimento ao longo das sete semanas previstas.

Par.	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Semana 6	Semana 7	Média
$\alpha$	0,9999978	0,9999977	0,9999978	0,9999972	0,9999972	0,9999972	0,9999971	0,9999974
$\gamma$	0,0000110	0,0000111	0,0000110	0,0000112	0,0000113	0,0000113	0,0000113	0,0000112
$\delta$	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000
$\omega$	0,5307907	0,5307907	0,5307907	0,5307907	0,5307907	0,5307907	0,5307907	0,5307907

Seguidamente apresenta-se o gráfico e a tabela resumo com a evolução dos vários erros de previsão calculados ao longo das sete semanas, tal como os gráficos das semanas com maior e menor erro de previsão (MAPE).




Figura 5.6 - Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas.

Tabela 5.6 - Valores dos erros, para as sete semanas previstas.

Semana	MAPE	QME	EMA	U
1	13,09%	571018	689,0	0,9086
2	12,85%	555851	677,5	0,9025
3	12,73%	536796	667,6	0,9047
4	12,88%	602507	706,0	1,0094
5	13,59%	735948	771,2	1,0163
6	16,15%	1205234	956,3	1,0187
7	14,31%	964961	862,7	1,0172




Figura 5.7 - Valores previstos relativos à melhor semana (terceira semana).




Figura 5.8 - Intervalo de confiança de 95% para a melhor semana prevista.




Figura 5.9 - Valores previstos relativos à pior semana (sexta semana).




Figura 5.10 - Intervalo de confiança de 95% para a pior semana prevista.

### 5.2.1.3 Série de 2 anos de dados com 17524 observações

Este modelo foi também construído com uma série de dados de dois anos (Outubro de 2010 até Outubro de 2012) e com valores horários (17524 observações), com o objetivo de prever as sete semanas seguintes individualmente. O modelo ajustado apresenta as

medidas de erro e de qualidade do ajuste expostas na tabela seguinte, para as 17524 observações.

Tabela 5.7 - Medidas de erro e de qualidade do ajuste do modelo.

Modelo	$R^2$	U	EMA	QME	MAPE [%]
HW multiplicativo	1	0,0005	0,1283	0,0258	0,0023

Em seguida, tal como nos pontos anteriores, foi necessário otimizar o modelo a cada semana que se pretendia prever, obtendo dessa forma sete valores diferentes para cada constante de amortecimento. Estes valores podem ser observados na tabela seguinte.

Tabela 5.8 - Valores das constantes de amortecimento ao longo das sete semanas previstas.

Par.	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Semana 6	Semana 7	Média
$\alpha$	0,9999613	0,9999609	0,9999609	0,9999615	0,9999607	0,9999604	0,9999604	0,9999609
$\gamma$	0,0001112	0,0001107	0,0001103	0,0001097	0,0001091	0,0001086	0,0001086	0,0001097
$\delta$	0,3758671	0,3758671	0,3758671	0,3758671	0,3758671	0,3758671	0,3758671	0,3758671
$\omega$	0,4174399	0,4174399	0,4174399	0,4174399	0,4174399	0,4174399	0,4174399	0,4174399

Apresenta-se também o gráfico e a tabela resumo com a evolução dos vários erros de previsão calculados ao longo das sete semanas, tal como os gráficos das semanas com maior e menor erro de previsão (MAPE).




Figura 5.11- Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas.

Tabela 5.9 - Valores dos erros, para as sete semanas previstas.

Semana	MAPE	QME	EMA	U
1	12,06%	491949	615,9	0,8125
2	11,74%	463729	596,9	0,8021
3	12,06%	481813	618,0	0,8053
4	12,07%	493819	645,4	0,9393
5	12,65%	583983	701,0	0,9587
6	15,32%	1011257	895,4	0,9928
7	13,33%	753110	786,4	0,9711




Figura 5.12 - Valores previstos relativos à melhor semana prevista (segunda semana).




Figura 5.13 - Intervalo de confiança de 95% para a melhor semana prevista.




Figura 5.14 - Valores previstos relativos à pior semana prevista (sexta semana).




Figura 5.15 - Intervalo de confiança de 95% para a pior semana prevista.

## 5.2.2 Modelo de *Holt-Winters* com Tendência Suavizada

### 5.2.2.1 Série de 1 ano de dados com 8762 observações

Relativamente ao modelo com tendência suavizada, tal como no modelo anterior, este foi desenvolvido com uma série de dados de um ano (Outubro de 2011 até Outubro de 2012) e com valores horários (8762 observações), com o objetivo de prever as sete semanas seguintes individualmente. O modelo ajustado apresenta as seguintes medidas de erro

(QME, MAPE e EMA) e de qualidade do ajuste  $U_{theil}$  e  $R^2$ , para as 8762 observações do ajuste.

Tabela 5.10 - Medidas de erro e de qualidade do ajuste do modelo.

Modelo	$R^2$	U	EMA	QME	MAPE [%]
HW multiplicativo	0,9885	0,3255	71,75	11561,4	1,29

Em seguida o modelo foi otimizado, para cada semana que se pretendia prever, obtendo dessa forma um conjunto de sete valores diferentes para cada constante de amortecimento. Estes valores podem ser vistos na tabela seguinte, na qual também se apresenta a média das constantes de amortecimento.

Tabela 5.11 - Valores das constantes de amortecimento ao longo das sete semanas previstas.

Par.	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Semana 6	Semana 7	Média
$\alpha$	0,2586380	0,2569245	0,2637549	0,2645557	0,2670421	0,2657543	0,2676555	0,2634750
$\gamma$	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000
$\delta$	0,6765116	0,6741421	0,6665252	0,6662760	0,6744665	0,6829488	0,6838303	0,6749572
$\omega$	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000
$\Phi$	0,2988143	0,2978883	0,2984546	0,2983211	0,2999128	0,2983269	0,2987952	0,2986447

Apresenta-se também o gráfico e a tabela resumo com a evolução dos vários erros de previsão calculados ao longo das sete semanas, tal como os gráficos com as semanas com maior e menor erro de previsão (MAPE).




Figura 5.16 - Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas.

Tabela 5.12 - Valores dos erros, para as sete semanas previstas.

Semana	MAPE	QME	EMA	U
1	1,54%	10479	81,6	0,3322
2	1,49%	10388	79,1	0,3211
3	2,32%	24491	125,5	0,4662
4	4,64%	99639	243,2	1,3855
5	3,94%	59781	214,5	0,6214
6	1,71%	15583	96,0	0,3794
7	2,79%	42010	163,6	0,5397






Figura 5.17 - Valores previstos relativos à melhor semana prevista (segunda semana).




Figura 5.18 - Intervalo de confiança de 95% para a melhor semana prevista.




Figura 5.19 - Valores previstos relativos à pior semana prevista (quarta semana).




Figura 5.20 - Intervalo de confiança de 95% para a pior semana prevista.

### 5.2.2.2 Série de 1 ano de dados com 17524 observações

Foi também desenvolvido este modelo com uma série de dados de um ano (Outubro de 2011 até Outubro de 2012), mas com valores de 30 em 30 minutos (17524 observações), com o objetivo de prever as sete semanas seguintes individualmente. O modelo ajustado apresenta as medidas de erro e de qualidade do ajuste expostas na tabela seguinte, para as 17524 observações.

Tabela 5.13 - Medidas de erro e de qualidade do ajuste do modelo.

Modelo	$R^2$	U	EMA	QME	MAPE [%]
HW multiplicativo	0,9915	0,4479	62,83	8269,8	1,11

Em seguida foi necessário otimizar o modelo a cada semana que se pretendia prever, obtendo dessa forma sete valores diferentes para cada constante de amortecimento. Estes valores podem ser vistos na tabela seguinte.

Tabela 5.14 - Valores das constantes de amortecimento ao longo das sete semanas previstas.

Par.	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Semana 6	Semana 7	Média
$\alpha$	0,6699143	0,6694931	0,6689628	0,6686884	0,6686676	0,6686843	0,6677178	0,6688759
$\gamma$	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000
$\delta$	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000
$\omega$	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000
$\Phi$	0,3885813	0,3885813	0,3885813	0,3885813	0,3885813	0,4569750	0,3885813	0,3983518

Seguidamente apresenta-se a Figura 5.21 e a Tabela 5.15 com a evolução dos vários erros de previsão calculados ao longo das sete semanas, tal como os gráficos das semanas com maior e menor erro de previsão (MAPE).




Figura 5.21 - Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas.

Tabela 5.15 - Valores dos erros, para as sete semanas previstas.

Semana	MAPE	QME	EMA	U
1	2,47%	23580	122,7	1,0000
2	2,82%	31983	144,7	0,8902
3	3,13%	42135	163,8	0,9501
4	8,37%	294172	440,6	1,1932
5	8,23%	342970	464,4	1,1490
6	8,50%	401019	504,5	1,0620
7	4,79%	114027	269,7	0,9302




Figura 5.22 - Valores previstos relativos à melhor semana prevista (primeira semana).




Figura 5.23 - Intervalo de confiança de 95% para a pior semana prevista.




Figura 5.24 - Valores previstos relativos à pior semana prevista (sexta semana).




Figura 5.25 - Intervalo de confiança de 95% para a pior semana prevista.

### 5.2.2.3 Série de 2 anos de dados com 17524 observações

Este modelo foi também construído com uma série de dados de dois anos (Outubro de 2010 até Outubro de 2012) e com valores horários (17524 observações), com o objetivo de prever as sete semanas seguintes individualmente. O modelo ajustado apresenta as

medidas de erro e de qualidade do ajuste exibidas na tabela seguinte, para as 17524 observações.

Tabela 5.16 - Medidas de erro e de qualidade do ajuste do modelo.

Modelo	$R^2$	U	EMA	QME	MAPE [%]
HW multiplicativo	0,9911	0,2901	68,08	10009,9	1,18

Em seguida, tal como nos pontos anteriores, foi necessário otimizar o modelo a cada semana que se pretendia prever, obtendo dessa forma sete valores diferentes para cada constante de amortecimento. Estes valores podem ser vistos na tabela seguinte.

Tabela 5.17 - Valores das constantes de amortecimento ao longo das sete semanas previstas.

Par.	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Semana 6	Semana 7	Média
$\alpha$	0,5977232	0,5971819	0,9999609	0,9999615	0,9999607	0,9999604	0,9999604	0,8849584
$\gamma$	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000
$\delta$	0,7257027	0,7241246	0,7249477	0,7250984	0,7280943	0,7279752	0,7447241	0,7286667
$\omega$	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000
$\Phi$	0,2888421	0,2889246	0,2882026	0,2888480	0,2883953	0,2901753	0,2881721	0,2887943

Apresenta-se também o gráfico e a tabela resumo com a evolução dos vários erros de previsão calculados ao longo das sete semanas, tal como os gráficos das semanas com maior e menor erro de previsão.




Figura 5.26 - Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas.

Tabela 5.18 - Valores dos erros, para as sete semanas previstas.

Semana	MAPE	QME	EMA	U
1	2,16%	21617	115,1	0,4544
2	1,57%	12082	84,0	0,3333
3	2,02%	17707	108,0	0,4078
4	5,34%	127520	278,0	1,4055
5	3,91%	69168	217,4	0,9038
6	3,54%	78738	207,1	0,6911
7	3,91%	58060	213,4	0,5961




Figura 5.27 - Valores previstos relativos à melhor semana prevista (segunda semana).




Figura 5.28 - Intervalo de confiança de 95% para a melhor semana prevista.




Figura 5.29 - Valores previstos relativos à pior semana prevista (quarta semana).






Figura 5.30 - Intervalo de confiança de 95% para a pior semana prevista.

### 5.2.3 Modelo de *Holt-Winters* com Tendência Suavizada e Erros Estruturados

#### 5.2.3.1 Série de 1 ano de dados com 8762 observações

Para o modelo com tendência suavizada e erros estruturados foi seguido o mesmo procedimento apresentado nos modelos anteriores, ou seja, nesta situação o modelo foi construído com uma série de dados de um ano (Outubro de 2011 até Outubro de 2012) e com valores horários (8762 observações), e foram previstas as sete semanas seguintes de forma independente. O modelo ajustado apresenta as seguintes medidas de erro (QME, MAPE e EMA) e de qualidade do ajuste  $U_{theil}$  e  $R^2$ , para as 8762 observações do ajuste.

Tabela 5.19 - Medidas de erro e de qualidade do ajuste do modelo.

Modelo	$R^2$	U	EMA	QME	MAPE [%]
HW multiplicativo	0,9891	0,3067	70,25	10974,2	1,26

Tal como nos modelos anteriores, foi otimizado o modelo para cada semana que se pretendia prever, os valores dos parâmetros resultantes para cada semana podem ser vistos na tabela seguinte.

Tabela 5.20 - Valores das constantes de amortecimento ao longo das sete semanas previstas.

Par.	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Semana 6	Semana 7	Média
$\alpha$	0,2488195	0,2495233	0,2509985	0,2566930	0,2628228	0,2618334	0,2623015	0,2561417
$\gamma$	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000
$\delta$	0,6839097	0,6850435	0,6846473	0,6906046	0,6992610	0,6987180	0,6984007	0,6915121
$\omega$	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000
$\Phi$	0,3014048	0,2985980	0,2988106	0,2991785	0,2978002	0,2973904	0,2973989	0,2986545
$\lambda$	0,0562144	0,0550032	0,0546478	0,0542422	0,0571891	0,0573866	0,0564035	0,0558695

Apresenta-se seguidamente o gráfico e a tabela resumo com a evolução dos vários erros de previsão ao longo das sete semanas, tal como os gráficos com as semanas com erro de previsão (MAPE) mais elevado e mais baixo.




Figura 5.31 - Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas.

Tabela 5.21 - Valores dos erros, para as sete semanas previstas.

Semana	MAPE	QME	EMA	U
1	1,55%	10608	82,0	0,3334
2	1,49%	10545	79,4	0,3226
3	2,40%	26305	130,1	0,4772
4	4,59%	97587	241,0	1,3792
5	3,92%	65969	213,1	0,6744
6	1,74%	16295	97,8	0,3894
7	2,78%	41563	162,9	0,5385




Figura 5.32 - Valores previstos relativos à melhor semana prevista (segunda semana).




Figura 5.33 - Intervalo de confiança de 95% para a melhor semana prevista.




Figura 5.34 - Valores previstos relativos à pior semana prevista (quarta semana).




Figura 5.35 - Intervalo de confiança de 95% para a pior semana prevista.

### 5.2.3.2 Série de 1 ano de dados com 17524 observações

Foi também desenvolvido este modelo com uma série de dados de um ano (Outubro de 2011 até Outubro de 2012), mas com valores de 30 em 30 minutos (17524 observações), com o objetivo de prever as sete semanas seguintes. O modelo ajustado apresenta as medidas de erro e de qualidade do ajuste exibidas na tabela seguinte, para as 17524 observações.

Tabela 5.22 - Medidas de erro e de qualidade do ajuste do modelo.

Modelo	$R^2$	U	EMA	QME	MAPE [%]
HW multiplicativo	0,9929	0,3941	60,04	7231,9	1,06

Em seguida foi necessário otimizar o modelo a cada semana que se pretendia prever, obtendo dessa forma sete valores diferentes para cada constante de amortecimento. Estes valores podem ser vistos na tabela seguinte.

Tabela 5.23 - Valores das constantes de amortecimento ao longo das sete semanas previstas.

Par.	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Semana 6	Semana 7	Média
$\alpha$	0,6725039	0,7493561	0,7497764	0,7496852	0,7503937	0,7522384	0,7522384	0,7394560
$\gamma$	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000
$\delta$	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000
$\omega$	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000
$\Phi$	0,3885813	0,4626377	0,4601069	0,4591090	0,4584335	0,4569750	0,4533593	0,4484575
$\lambda$	0,1298074	0,1229354	0,1200344	0,1169954	0,1177770	0,1183872	0,1202616	0,1208855

Seguidamente apresenta-se o gráfico e a tabela resumo com a evolução dos vários erros de previsão calculados ao longo das sete semanas, tal como os gráficos das semanas com maior e menor erro de previsão (MAPE).




Figura 5.36 - Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas.

Tabela 5.24 - Valores dos erros, para as sete semanas previstas.

Semana	MAPE	QME	EMA	U
1	2,62%	26223	129,4	0,8553
2	4,91%	114123	269,7	0,8147
3	6,03%	166934	338,0	0,8852
4	5,13%	114649	276,2	1,1648
5	6,72%	184345	350,8	1,1688
6	10,40%	434370	572,8	1,0984
7	7,26%	254002	414,4	1,1425




Figura 5.37 - Valores previstos relativos à melhor semana prevista (primeira semana).




Figura 5.38 - Intervalo de confiança de 95% para a melhor semana prevista.




Figura 5.39 - Valores previstos relativos à pior semana prevista (sexta semana).




Figura 5.40 - Intervalo de confiança de 95% para a pior semana prevista.

### 5.2.3.3 Série de 2 anos de dados com 17524 observações

Este modelo foi também construído com uma série de dados de dois anos (Outubro de 2010 até Outubro de 2012) e com valores horários (17524 observações), com o objetivo de prever as sete semanas seguintes. O modelo ajustado apresenta as medidas de erro e de qualidade do ajuste expostas na tabela seguinte, para as 17524 observações.

Tabela 5.25 - Medidas de erro e de qualidade do ajuste do modelo.

Modelo	$R^2$	U	EMA	QME	MAPE [%]
HW multiplicativo	0,9914	0,2791	67,20	9696,8	1,17

Em seguida, tal como nos pontos anteriores, foi necessário otimizar o modelo a cada semana que se pretendia prever, obtendo dessa forma sete valores diferentes para cada constante de amortecimento. Estes valores podem ser vistos na tabela seguinte.

Tabela 5.26 - Valores das constantes de amortecimento ao longo das sete semanas previstas.

Par.	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Semana 6	Semana 7	Média
$\alpha$	0,5999667	0,5995322	0,9999609	0,5987877	0,9999607	0,9999604	0,9999604	0,8283041
$\gamma$	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000	1,0000000
$\delta$	0,7256367	0,7240210	0,6067061	0,7221484	0,7371720	0,7367954	0,7447241	0,7138862
$\omega$	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000	0,0000000
$\Phi$	0,2891602	0,2890196	0,2928265	0,2896438	0,2891312	0,2885421	0,2881721	0,2894993
$\lambda$	0,0401743	0,0398587	0,0397939	0,0397993	0,0408511	0,0430106	0,0434653	0,0409933

Apresenta-se também o gráfico e a tabela resumo com a evolução dos vários erros de previsão calculados ao longo das sete semanas, tal como os gráficos das semanas com maior e menor erro de previsão (MAPE).




Figura 5.41 - Evolução do erro percentual absoluto médio (MAPE) ao longo das sete semanas.



Tabela 5.27 - Valores dos erros, para as sete semanas previstas.

Semana	MAPE	QME	EMA	U
1	2,19%	22187	116,8	0,4616
2	1,59%	12325	84,9	0,3360
3	2,50%	25385	131,2	0,5204
4	5,36%	128264	279,3	1,4041
5	3,92%	69472	217,6	1,0000
6	3,54%	78589	207,0	0,6906
7	5,01%	109875	287,8	0,6705




Figura 5.42 - Valores previstos relativos à melhor semana prevista (segunda semana).




Figura 5.43 - Intervalo de confiança de 95% para a melhor semana prevista.




Figura 5.44 - Valores previstos relativos à pior semana prevista (quarta semana).




Figura 5.45 - Intervalo de confiança de 95% para a pior semana prevista.

### 5.3 Comparação dos Erros de Previsão em Função do Tamanho da Série

No seguimento dos resultados da previsão, obtidos para cada modelo, foi feita uma comparação com o objetivo de aferir com qual dos três tamanhos de série são obtidos menores erros de previsão, usou-se como critério de comparação os valores obtidos para o erro percentual absoluto médio (MAPE).

### 5.3.1 Modelo de *Holt-Winters* Multiplicativo




Figura 5.46 - Evolução do MAPE ao longo das sete semanas com diferentes tamanhos de série.

### 5.3.2 Modelo de *Holt-Winters* com Tendência Suavizada




Figura 5.47 - Evolução do MAPE ao longo das sete semanas com diferentes tamanhos de série.

### 5.3.3 Modelo de Holt-Winters com Tendência Suavizada e Erros Estruturados




Figura 5.48 - Evolução do MAPE ao longo das sete semanas com diferentes tamanhos de série.

Por análise das figuras 5.46, 5.47 e 5.48 pode retirar-se que a série de dados de 1 ano com 17524 observações apresenta piores resultados para qualquer um dos modelos. Já em relação às restantes dimensões de séries, apesar de apresentarem resultados bastante semelhantes, a série de 1 ano de dados com 8762 observações apresenta, na maioria das semanas, menor erro (MAPE) para os três modelos.

## 5.4 Comparação dos Modelos de Previsão

Neste ponto da dissertação é possível comparar os vários modelos desenvolvidos para as três dimensões distintas, de forma a ser possível verificar qual dos modelos e qual a dimensão da série de dados que apresenta menores erros de previsão.

### 5.4.1 Série de 1 ano de dados com 8762 observações




Figura 5.49 - Evolução do MAPE ao longo das sete semanas para os três modelos de previsão.

Apresenta-se em seguida a tabela com os valores de MAPE para os três modelos de *Holt-Winters* ao longo das sete semanas, tal como a sua média.

Tabela 5.28 - Valores do MAPE, para os três modelos de previsão e média das semanas.

Semana	HW Multiplicativo	HW T. Suavizada	HW T.S. e E.E.
1	11,88%	1,54%	1,55%
2	11,58%	1,49%	1,49%
3	11,96%	2,32%	2,40%
4	12,06%	4,64%	4,59%
5	12,64%	3,94%	3,92%
6	15,30%	1,71%	1,74%
7	13,28%	2,79%	2,78%
Média	12,67%	2,63%	2,64%

## 5.4.2 Série de 1 ano de dados com 17524 observações




Figura 5.50 - Evolução do MAPE ao longo das sete semanas para os três modelos de previsão.

Apresenta-se também a tabela com os valores de MAPE para os três modelos ao longo das sete semanas, tal como a sua média.

Tabela 5.29 - Valores do MAPE, para os três modelos de previsão e média das semanas.

Semana	HW Multiplicativo	HW T. Suavizada	HW T.S. e E.E.
1	13,09%	2,47%	2,62%
2	12,85%	2,82%	4,91%
3	12,73%	3,13%	6,03%
4	12,88%	8,37%	5,13%
5	13,59%	8,23%	6,72%
6	16,15%	8,50%	10,40%
7	14,31%	4,79%	7,26%
<b>Média</b>	13,66%	<b>5,47%</b>	6,15%

### 5.4.3 Série de 2 anos de dados com 17524 observações




Figura 5.51 - Evolução do MAPE ao longo das sete semanas para os três modelos de previsão e média das semanas.

Apresenta-se em seguida a tabela com os valores de MAPE para os três modelos ao longo das sete semanas, tal como a respetiva média.

Tabela 5.30 – Valores do MAPE, para os três modelos de previsão.

Semana	HW Multiplicativo	HW T. Suavizada	HW T.S. e E.E.
1	12,06%	2,16%	2,19%
2	11,74%	1,57%	1,59%
3	12,06%	2,02%	2,50%
4	12,07%	5,34%	5,36%
5	12,65%	3,91%	3,92%
6	15,32%	3,54%	3,54%
7	13,33%	3,91%	5,01%
<b>Média</b>	<b>12,75%</b>	<b>3,21%</b>	<b>3,44%</b>

Em seguida, apresenta-se a tabela com o resumo das médias do MAPE para os três modelos desenvolvidos e para as três dimensões distintas de forma a que seja possível concluir qual o modelo que em média apresenta menor erro de previsão (MAPE).



Tabela 5.31 – MAPE médio nas sete semanas para os três modelos e as três dimensões de séries

Semana	HW Multiplicativo	HW T. Suavizada	HW T.S. e E.E.
1 ano (8762 obs.)	12,67%	2,63%	2,64%
1 ano (17524 obs.)	13,66%	5,47%	6,15%
2 anos (17524 obs.)	12,75%	3,21%	3,44%

## 5.5 Análise da Evolução Horária do Erro de Previsão

Nos pontos anteriores, foi possível verificar que o modelo de *Holt-Winters* multiplicativo apresenta resultados pouco satisfatórios quando comparado com os dois restantes modelos. Dessa forma, nas próximas análises será dada particular atenção aos resultados obtidos com os modelos que produziram melhores resultados, sendo eles:

- Modelo de *Holt-Winters* com tendência suavizada;
- Modelo de *Holt-Winters* com Tendência suavizada e erros estruturados.

Quanto à dimensão da série de dados, foi também verificado que a série de um ano com 8762 observações apresenta melhores resultados, logo a análise dos modelos será feita para essa mesma dimensão.

Nesta situação, pretende-se verificar a existência intervalos de tempo, ao longo da semana, em que o QME é mais elevado. Isto significa que, nestes intervalos de tempo torna-se mais problemático prever o valor real de consumo de energia elétrica.

### 5.5.1 Modelo de *Holt-Winters* com Tendência Suavizada

Neste ponto, pretende-se observar se existem horas no decorrer de cada dia em que o erro quadrático médio apresenta maiores valores, ou seja, se existe alguma altura do dia em que é mais difícil prever o valor do consumo de energia.




Figura 5.52 - Evolução horária do QME para a melhor semana prevista.




Figura 5.53 - Evolução horária do QME para três semanas previstas.

### 5.5.2 Modelo de Holt-Winters com Tendência Suavizada e Erros Estruturados

Tal como no ponto anterior, pretende-se observar se existem horas no decorrer de cada dia em que o erro quadrático médio apresenta maiores valores, ou seja, se existe alguma altura do dia em que o modelo apresenta maior dificuldade prever o valor do consumo de energia.




Figura 5.54 - Evolução horária do QME para a melhor semana prevista.




Figura 5.55 - Evolução horária do QME para três semanas previstas.

Para o conjunto de 5.5.1 e 5.5.2 que corresponde às figuras 5.52, 5.53, 5.54 e 5.55, verifica-se que nas diferentes semanas para as quais se efetuaram previsões, o valor do QME é semelhante e de maior amplitude aproximadamente entre as 11 e 16 horas de cada dia. Esta situação mostra que é neste período de tempo que se torna mais complexo prever o consumo de energia elétrica.



---

## Capítulo 6

---

### Conclusões

*Neste Capítulo são apresentadas as principais conclusões acerca do trabalho realizado nos capítulos anteriores, bem como apresentadas as perspectivas de evolução do trabalho e hipóteses de trabalhos futuros.*



## 6 Conclusões

Este trabalho consistiu na realização de um estudo teórico de diversos métodos de previsão existentes, especificamente os métodos de alisamento exponencial de *Holt-Winters* com dois ciclos sazonais. Tendo como ponto de partida os conceitos que explicam o consumo de energia elétrica em Portugal, tais como, aspetos gerais sobre diagramas de carga semanais típicos e evolução do consumo ao longo dos últimos anos. Foi apresentada toda a modelização de forma a ser possível desenvolver os modelos de previsão utilizados nesta dissertação.

A implementação prática da modelização apresentada foi efetuada de forma a que a complexidade dos modelos fosse aumentando, sendo que, pelo fato de apresentarem uma configuração mais simplificada, os modelos de *Holt-Winters* aditivo e multiplicativo foram o ponto de partida para o desenvolvimento dos modelos mais complexos. De referir ainda que, o modelo *Holt-Winters* com sazonalidade aditiva não foi apresentado nesta dissertação, uma vez que apresentava à partida resultados pouco satisfatórios.

Os resultados apresentados pelos modelos de previsão desenvolvidos permitem concluir, de uma forma geral, que se obtêm previsões com um elevado grau de precisão, em especial os modelos de *Holt-Winters* mais complexos, como sendo, o modelo com tendência amortecida e modelo com tendência amortecida e erros estruturados.

Nesta dissertação os modelos de previsão foram também desenvolvidos e testados com dimensões de séries de dados distintas. De uma forma geral, este estudo permitiu concluir que ao aumentar o número de observações, mantendo o mesmo horizonte temporal para teste (1 ano), os resultados foram piores em comparação com as restantes dimensões de série de dados testadas. No caso do incremento do número de observações através do aumento do horizonte temporal para teste (2 anos), os resultados não foram tão conclusivos apesar de, na maioria das semanas, os modelos apresentarem erros mais elevados relativamente aos que foram desenvolvidos com 1 ano de dados horários.

Os casos de estudo abordados neste trabalho, foram estruturados de modo a permitir uma clara perceção da implementação dos modelos de *Holt-Winters* e das principais conclusões que foram possíveis retirar dos mesmos. Em primeiro lugar, foram apresentados os resultados mais relevantes relativamente aos três modelos desenvolvidos sendo eles:

- Modelo de *Holt-Winters* multiplicativo;

- Modelo de *Holt-Winters* com tendência suavizada;
- Modelo de *Holt-Winters* com Tendência suavizada e erros estruturados.

Sendo que cada um dos destes modelos foi desenvolvido e ajustado utilizando três dimensões distintas de série de dados:

- 1 Ano com 8762 observações (hora a hora);
- 1 Ano com 17524 observações (30 em 30 min);
- 2 Anos 17524 observações (hora a hora).

Inicialmente nos pontos 5.2.1 5.2.2 e 5.2.3 são apresentadas as tabelas com os valores das medidas de erro e de qualidade de ajuste dos modelos para todas as variantes anteriormente referidas. Através da observação destas tabelas, é possível concluir que todos os modelos apresentam medidas de erro e de qualidade bastante aceitáveis, o que torna desde logo prometedora a ideia de se utilizar estes modelos para prever o consumo de energia em Portugal.

Em seguida, apresentou-se também as constantes de amortecimento ao longo das sete semanas de previsão e a sua média para todos os modelos desenvolvidos. Ao observar-se essas mesmas tabelas, é possível verificar que os valores das constantes não variam significativamente cada vez que o modelo é otimizado para cada semana, consequentemente foram testados os modelos utilizando a média de cada constante ao longo das sete semanas. Desta análise foi possível concluir que essa alteração não produz alterações significativas nas previsões geradas pelo modelo, o que pode simplificar ainda mais a utilização destes modelos.

Relativamente ainda às constantes de amortecimento verifica-se que para os modelos com tendência suavizada e tendência suavizada com erros estruturados a constante  $\omega$  apresenta valor nulo, ou seja, após o ajuste do modelo o peso desta constante é desprezável nas equações de atualização do modelo, o que levará a simplificação destas mesmas equações.

Posteriormente a esta análise, são apresentados alguns resultados das previsões geradas pelos modelos desenvolvidos, tais como a evolução dos erros ao longo das sete semanas previstas, em especial do MAPE, e também de forma a ser perceptível a grandeza dos erros, apresentam-se as figuras das semanas que denotam maior e menor erro de previsão (MAPE). Simultaneamente, são apresentados os gráficos com os intervalos de confiança



de 95% para as semanas com maior e menor erro, onde se observa desde logo que o modelo multiplicativo apresenta resultados muito aquém dos restantes dois modelos.

No ponto 5.3 é feita uma comparação do erro de previsão (MAPE), utilizando os três tamanhos de série distintos para cada modelo, com o objetivo de aferir a dimensão de série de dados mais adequada para obter melhores resultados. Observando as figuras 5.46, 5.47 e 5.48, verifica-se que o modelo quando desenvolvido com uma série de dados de 1 ano com 17524 observações apresenta piores resultados comparativamente com as duas restantes dimensões de série. Ao analisar os resultados obtidos pelo modelo com a série de 2 anos com 17524 observações e com a série de 1 ano de dados e 8762 observações (observações horárias), pode concluir-se que a série de 1 ano de dados apresenta resultados ligeiramente melhores para os três modelos e na maioria das sete semanas previstas.

No ponto seguinte da dissertação (5.4), o mesmo tema é apresentada de maneira diferente, ou seja, para cada tamanho de série, são comparados os três modelos de forma a ser possível concluir qual o modelo que apresenta melhores resultados para as sete semanas previstas. Observando as figuras 5.49, 5.50 e 5.51 é possível concluir que o modelo de *Holt-Winters* multiplicativo apresenta piores resultados em todas as variantes de séries de dados testadas. Quando aos restantes modelos ambos apresentam resultados bastante satisfatórios principalmente quando ajustados com a série de dados de 1 anos com 8762 observações, como foi dito anteriormente. Analisando a Tabela 5.31, conclui-se que o modelo com tendência suavizada apresenta resultados ligeiramente melhores quando comparado com o modelo com tendência suavizada e erros estruturados, para todas as dimensões de série de dados.

Na situação 5.5, pretendeu-se observar se existem horas no decorrer de cada dia em que o erro quadrático médio apresenta maiores valores, ou seja, se existe alguma altura do dia em que é mais difícil prever o valor do consumo de energia. Analisando as figuras 5.52, 5.53, 5.54 e 5.55, verifica-se que nas diferentes semanas para as quais se efetuaram previsões, o valor do QME é semelhante e de maior amplitude aproximadamente entre as 11 e 16 horas de cada dia. Esta situação mostra que é neste período de tempo que se torna mais complexo prever o consumo de energia elétrica.

## 6.1 Desenvolvimentos futuros

Relativamente a possíveis desenvolvimentos futuros desta dissertação é possível estabelecer um conjunto de direções de investigação pertinentes. Como desenvolvimento deste trabalho seria interessante testar os vários modelos, especialmente os modelos de tendência amortecida e tendência amortecida com erros estruturados em mais semanas, uma vez que nesta dissertação foram testados apenas em sete semanas.

Seria também interessante neste âmbito testar os modelos em alturas diferentes do ano, uma vez que, como pode ser lido neste trabalho o consumo de energia apresenta algumas variações ao longo do ano, especialmente nas estações mais extremas em termos de temperatura (Inverno e Verão).

Outro dos aspetos que poderia ser desenvolvido seria a utilização destes modelos para efetuar a previsão do consumo para um intervalo de tempo mais reduzido (próximas 24 horas), devido ao fato de este tipo de previsões apresentarem um grau de incerteza menor, seria interessante testar se os modelos melhorariam significativamente os seus resultados nesta situação.

Na perspetiva da simplificação do modelo poder-se-ia testar a eliminação de algumas constantes de amortecimento, cujos resultados desta dissertação apontam para a pouca influência na eficiência do modelo ( $\omega$  é nulo nos modelos com tendência suavizada e tendência suavizada com erros estruturados). Isto deve-se ao fato do consumo de energia em Portugal estar a diminuir, logo a necessidade de amortecer a tendência de amortecimento torna-se irrelevante.

Da mesma forma, poderiam ser desenvolvidos modelos para prever separadamente os dias de semana e os de fim-de-semana, uma vez que como foi explicitado no ponto 3.2 desta dissertação, existe uma notória diferença no padrão destes dois tipos de consumos diários.

Outra direção que poderia ser tomada passaria por testar outro tipo de modelos de *Holt-Winters* para prever o consumo de energia elétrica em Portugal, como por exemplo os modelos com tripla sazonalidade descritos em [29].

**Referências**

**Bibliográficas**



## Referências Bibliográficas

- [1] J. W. Taylor, "Short-Term Electricity Demand Forecasting Using Double Seasonal Exponential Smoothing," *Journal of Operational Research Society*, 2003.
- [2] T. Y. Lin, "Estudo de modelos de previsão de demanda".
- [3] V. M. B. d. Almeida, "Estudo de modelos de previsão de demanda para reposição de produtos de consumo," 2010.
- [4] S. A.-h. Soliman e A. M. Al-Kandari, *Electrical load forecasting : modeling and model construction*, 2010.
- [5] R. H. Ballou, *Business Logistics/Supply Chain Management*, 2004.
- [6] B. L. Bowerman e R. T. O'Connell, *Forecasting and time series:an applied aproach*, Wadsworth, 1993.
- [7] M. R. Furtado, "Aplicação de um modelo de demanda total nos credenciados belgo pronto," 2006.
- [8] P. S. Kalekar, "Time series Forecasting using Holt-Winters Exponential Smoothing," 2004.
- [9] J. W. Taylor, "Exponential Smoothing with a Damped Multiplicative Trend," *International Journal of Forecasting* , vol. 19, 2003.
- [10] A. L. Maia e F. d. A. Carvalho, "Holt's Exponential smoothing and neural network models for forecasting interval-value time series".
- [11] Y. Gao, Y. Liang, S. Zhan, X. Ren e Z. Ou, "Realization of a Demand forecasting Algorithm for Retail Industry," 2011.
- [12] J. W. Taylor, "An evolution of methods for very short-term load forecasting using minute-by-minute British data," *International Journal of forecasting*,

2008.

- [13] R. C. Souza, M. Barros e C. C. Miranda, “Previsão horária de carga eléctrica usando Holt-Winters,” 2006.
- [14] A. Cruz, A. Muñoz, J. L. Zamora e R. Espínola, “The effect of wind generation and weekday on Spanish electricity spot price forecasting,” *Elsevier*, 2011.
- [15] REN, “Redes Energéticas Nacionais,” [Online]. Available: [www.ren.pt](http://www.ren.pt). [Acedido em 11 12 2012].
- [16] H. L. Willis e W. G. Scott, *Distributes Power Generation*, Basel: Marcel Dekker, 2000.
- [17] DGEG, “Direcção Geral de Energia e Geologia,” [Online]. Available: <http://www.dgeg.pt/>. [Acedido em 19 11 2012].
- [18] REE, “Rede eléctrica de Espanha,” [Online]. Available: <http://www.ree.es>. [Acedido em 10 12 2012].
- [19] RTE, “Rede de Transporte de Electricidade de França,” [Online]. Available: <http://www.rte-france.com>. [Acedido em 8 1 2013].
- [20] R. Garber, “Análise de séries temporais,” 1995.
- [21] E. S. G. Jr., “Exponential smoothing: The state of the art- Part II,” *International Journal of Forecasting*, 2006.
- [22] J. W. Taylor, “Exponential Smoothing with a Damped Multiplicative Trend,” *International Journal of Forecasting*, 2003.
- [23] C. Camus, “A Metaheuristic Approach to the Holt-Winters Optimal Short Term Load Forecast,” 2008.
- [24] G. d. P. Falco, “Técnicas Univariadas Aperfeiçoadas para a Previsão de Curtíssimo Prazo a partir de Dados Horários,” 2005.
- [25] A. Dzikevičius e S. Šaranda, *Smoothing Techniques for market fluctuation signals*, 2010.

- [26] M. R. Furtado, “Aplicação de um modelo de previsão da demanda total nos credenciados pelo pronto,” 2006.
- [27] D. o. Treasury, “Forecasting accuracy of the act budget estimates,” 2008.
- [28] A. O. Cutrim e A. d. C. Rebouças, “Aplicação do método de holt na previsão de dados de água da cidade de Rondópolis-MT”.
- [29] J. W. Taylor, “Triple Seasonal Methods for Short-Term Electricity Demand Forecasting,” *European Journal of Operational Research*, 2010.